

**Automatická identifikace druhu
provozu pro SDR rádio**

**Radio Modulation Modes Detection
for SDR Radio**

Zadání diplomové práce

Student: **Bc. Jakub Stebel**

Studijní program: N2647 Informační a komunikační technologie

Studijní obor: 2612T059 Mobilní technologie

Téma: Automatická identifikace druhu provozu pro SDR rádio
Radio Modulation Modes Detection for SDR Radio

Jazyk vypracování: čeština

Zásady pro vypracování:

Cílem práce je implementovat modul umožňující na základě vstupních I/Q dat zachycených SDR rádiem identifikovat druh radioamatérského provozu (CW/SSB/AM/FM) včetně nepoužívanějších digitálních modulací. Výstupem může být jak samostatná aplikace, tak i modul použitelný v rámci GNURadio.

1. Prostudujte koncepcce softwarově definovaných rádií (SDR) a metody jejich realizace.
2. Seznamte se s aplikací GNURadio a parametry používaných modulací.
3. Navrhněte a implementujte aplikaci, která na základě vstupních I/Q dat rozpozná typ modulace (případně další podrobnější informace).
4. Navržené řešení otestujte na umělých i reálných datech z SDR rádia.
5. Vyhodnoťte dosaženou úspěšnost v identifikaci typu modulace a provozu.

Seznam doporučené odborné literatury:

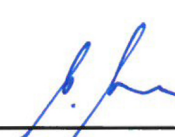
- [1] Jeffrey H. Reed, Software Radio - A modern Approach to Radio Engineering. Upper Saddle River: Prentice Hall, 2002. ISBN 0130811580
- [2] Eugene Grayver, Implementing Software Defined Radio, Springer; 2012. ISBN 1441993312
- [3] Robert G. Gallager, Principles of Digital Communication, Cambridge University Press, 2008. ISBN 0521879078

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.


Vedoucí diplomové práce: **Mgr. Ing. Michal Krumnikl, Ph.D.**

Datum zadání: 01.09.2015

Datum odevzdání: 29.04.2016


doc. Ing. Miroslav Vozňák, Ph.D.
vedoucí katedry




prof. RNDr. Václav Snášel, CSc.
děkan fakulty

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

V Ostravě 29. dubna 2016

.....

Rád bych na tomto místě poděkoval všem přátelům, rodině i panu Mgr. Ing. Michalovi Krumníkovi, Ph.D., který mou práci vedl, za podporu a trpělivost, kterou projevili. Bez nich by tato práce nikdy nevznikla.

Abstrakt

Diplomová práce na téma Automatická identifikace druhu provozu pro SDR rádio se věnuje teoretickému i praktickému rozboru metod používaných při klasifikaci modulací rádiového signálu. Hlavním cílem práce je rozebrat a použít tyto metody při implementaci klasifikačního softwaru. Řešení v první řadě využívá statistické analýzy, která je realizována výpočtem klíčových charakteristik signálu. Vypočtené hodnoty slouží jako vstup pro neuronovou síť, která na jejich základě klasifikuje druh použité modulace. Úspěšnost modelu neuronové sítě byla zkoumána na základě testování s umělými i reálnými daty.

Klíčová slova: Softwarově definované rádio, modulační techniky, klasifikace

Abstract

This diploma thesis is written on the topic Radio Modulation Modes Detection for SDR Radio. It focuses on theoretical and practical analysis of techniques used for classification of radio signal modulations. The main goal of this work is to present and use these techniques within the classification software implementation. The solution is based on statistical analysis, which is performed by calculation of the signal key features. These characteristics are used as inputs to the artificial neural network which performs the classification process. Success rate of the created model has been tested by performing validation tests with simulated and real data sets.

Keywords: Software defined radio, modulation techniques, classification

Seznam použitých zkratek a symbolů

ALRT	– Avarage likelihood ratio test
AM	– Amplitudová modulace
AMC	– Automatická klasifikace modulací
ASIC	– Application-Specific integrated circuit
ASK	– Amplitude shift keying
AWGN	– Aditivní, bílý, gaussovský šum
BFSK	– Binary frequency shift keying
BPSK	– Binary phase shift keying
DDC	– Direc digital conversion
DFT	– Diskrétní Fourierova transformace
DVB-T	– Digitální pozemní vysílání
FIR	– Finite impulse response
FM	– Frekvenční modulace
FSK	– Frequency shift keying
GLRT	– General likelihood ratio test
GRC	– GNU Radio Companion
HLRT	– Hybrid likelihood ratio test
I/Q	– In-phase quadrature
IIR	– Infinite impulse response
MSK	– Minimal shift keying
MVVM	– Model, view, viewmodel
PM	– Fázová modulace
PSK	– Phase shift keying
QPSK	– Quadrature phase shift keying
RBF	– Radial basis function
RTAD	– Radio traffic automatic detector
SDR	– Softwarově definované rádio
SSB	– Single side band
SVM	– Support vector machine
WBFM	– Wide band frequency modulation
WPF	– Windows presentation foundation

Obsah

1	Úvod	5
2	Softwarově definované rádio	7
2.1	Koncepty SDR a princip jejich fungování	8
2.2	Omezení a rizika SDR technologie	9
3	Modulace a komplexní signál	11
3.1	Reálná a imaginární složka komplexního signálu	11
3.2	Okamžitá amplituda	12
3.3	Okamžitá fáze	12
3.4	Okamžitá frekvence	13
4	Zarušení signálu	15
4.1	Bílý šum	15
4.2	Barevný šum	15
4.3	Impulzní šum	15
4.4	Metody minimalizace šumu	16
5	Rešerše možných řešení	17
5.1	Využití pravděpodobnostních funkcí	17
5.2	Zkoumání vlastností digitálního signálu	19
5.3	Přehled existujících implementací	21
6	Praktická realizace v jazyce C#	23
6.1	Vstup	23
6.2	Vývojový diagram	31
6.3	Detekce signálu a šumu	33
6.4	Aplikace filtrů	33
6.5	Implementace klíčových faktorů	35
6.6	Vytváření modelů neuronové sítě	38
6.7	Výstup	39
7	Validace úspěšnosti řešení	40
7.1	Ověření vhodnosti použitých statistických charakteristik	40
7.2	Testy nad umělými daty	45
7.3	Testy nad reálnými daty	50
8	Závěr	52
9	Reference	54
	Přílohy	56

A Appendix	56
A.1 Vývojový diagram řešení	56

Seznam tabulek

1	Nejběžnější klasifikační techniky používané pro rozpoznání druhu modulace	18
2	Nejčastější druhy šumu a možnosti jejich potlačení	18
3	Výsledky modelu RBF na nezarušeném vstupním signálu	45
4	Výsledky modelu Feed forward na nezarušeném vstupním signálu	46
5	Výsledky modelu RBF pro odstup signálu od šumu 35 - 45 dB	46
6	Výsledky modelu Feed forward pro odstup signálu od šumu 35 - 45 dB . .	47
7	Výsledky modelu RBF pro odstup signálu od šumu 25 - 35 dB	47
8	Výsledky modelu Feed forward pro odstup signálu od šumu 25 - 35 dB . .	47
9	Výsledky modelu RBF pro odstup signálu od šumu 15 - 25 dB	48
10	Výsledky modelu Feed forward pro odstup signálu od šumu 15 - 25 dB . .	48
11	Úspěšnost klasifikačního modelu sítě Feed forward pro reálná data	50

Seznam obrázků

1	Metoda přímé digitální konverze v SDR topologii	8
2	Analogové směšování do základního pásma v SDR	8
3	Základní topologie obvodu SDR přijímače	9
4	Vztah mezi I/Q vzorky a okamžitou amplitudou	12
5	Vztah mezi I/Q vzorky a okamžitou fází	13
6	Vztah mezi I/Q vzorky a okamžitou frekvencí	14
7	Schéma AM modulátoru	25
8	Schéma FM modulátoru	25
9	Schéma PM modulátoru	26
10	Schéma ASK modulátoru	27
11	Schéma FSK modulátoru	28
12	Schéma PSK modulátoru	29
13	Schéma QAM modulátoru	29
14	Schéma měření SNR z kvadratického průměru amplitud signálu a šumu	30
15	Schéma pro příjem rádiových signálů pomocí čipu RTL2832U	31
16	Vývojový diagram programu RTAD	32
17	Blokové schéma konvoluční FIR filtru	34
18	Průběh klíčové veličiny γ_{max}	42
19	Průběh klíčové veličiny σ_{aa}	42
20	Průběh klíčové charakteristiky σ_{ap}	43
21	Průběh klíčové charakteristiky σ_{dp}	43
22	Průběh klíčové charakteristiky σ_{af}	44
23	Průběh symetrie frekvenčního spektra	44
24	Vývojový diagram RTAD	56

1 Úvod

Rád bych Vám představil svou diplomovou práci, pojednávající o problematice automatické identifikace druhu provozu pro SDR rádio.

Zpracování číslicových signálů je v současnosti jeden z mnoha rychle se rozvíjejících oborů, který má bezesporu své stálé místo v budoucnosti informačních technologií. Můžeme za to poděkovat neustále rostoucímu výkonu hardwarových komponent. Rychlost je totiž klíčovým elementem, umožňujícím efektivní práci s číslicovými signály v reálném čase. Výkonné počítače se navíc staly v průběhu poslední dekády finančně dostupnými i pro běžné uživatele či radioamatéry, kteří tak dnes mohou využívat výhod SDR rádií nebo se sami aktivně podílet na jeho rozvoji. Velkým přínosem softwarového rádia je tedy snaha o přiblížení oborů programování a rádiových komunikací pomocí snadno dostupných, dobře zdokumentovaných nástrojů, jejichž popularitu navíc zvyšuje fakt, že jsou obvykle zdarma. Nutno podotknout, že i přes zvyšující se počet odborníků, kteří mají slušné znalosti v obou oblastech, je pro širší odbornou veřejnost stále obtížné vyznat se v nepřehledném množství všech modulací a kódování. Tento fakt mne vedl k motivaci vytvořit automatizační software usnadňující práci SDR operátorům.

Jak již napovídá sám název, hlavním cílem celé práce je pochopení modulačních principů, využívaných v rádiové komunikaci a následné zpracování modulovaných digitálních signálů. Primárním stavebním kamenem však zůstává pochopení konceptu softwarově definovaného rádia a základních principů jeho fungování. Další nezbytností je podrobný rozbor problematiky analogových i digitálních modulací. Ty jsou v rámci SDR realizovány s využitím takzvaných In-phase quadrature (I/Q) signálů, často též označovaných jako signály komplexní či analytické. V neposlední řadě se dotkneme filtrování a transformací, sloužících například pro redukci bílého šumu a zkvalitnění zpracovávaného signálu.

Detailně popsané teoretické znalosti z první části práce následně demonstroe implementace desktopové aplikace v programovacím jazyce C# a .NET frameworku, využívající již existujících knihoven pro zpracování číslicových signálů. Problematika klasifikace je řešena pomocí biologicky inspirovaných algoritmů. Konkrétně se jedná o aplikaci klasifikačního modelu neuronové sítě. Na vstupu se objevuje zachycený komplexní, diskretní signál, zakódovaný neznámým typem modulace. Pro simulaci vstupních dat bylo využito aplikace GNU Radio Companion (GRC), která je součástí distribuce stejnojmenného populárního SDR nástroje GNU Radio, šířeného pod GPL licenci. Další testy probíhaly nad reálnými signály, zachycenými na hardwarový SDR přijímač Sencor SDB522RT. Úkolem programu je, na základě vstupních dat spočítat příslušné statistické klíčové charakteristiky vstupního signálu, které jsou poslány do vytvořeného modelu neuronové sítě. S jeho pomocí se co možná nejpřesněji určí druh použitého radioamatérského provozu, neboli modulace. V průběhu celého procesu jsou vstupní data matematicky zpracovávána tak, aby z nich bylo možné dostat co nejvíce podrobností. Program počítá s podporou základních modulačních tříd, jako je amplitudová modulace (AM), frekvenční modulace (FM), fázová modulace (PM) nebo klíčování amplitudovým, frekvenčním i fázovým posuvem (ASK, FSK, PSK). Zahrnuta je také dnes velmi rozšířená kvadratická amplitu-

dová modulace (QAM).

Poslední fází vývoje automatického klasifikátoru modulací je jeho testování, ilustrující přesnost celého systému při určování typů radioamatérského provozu v závislosti na odstupu signálu od šumu.

Volbu tématu diplomové práce, týkající se softwarově definovaného rádia, pravděpodobně ovlivnila moje předešlá pozitivní zkušenost s touto technologií. V průběhu mého studia jsem totiž používal malý SDR přijímač pro poslech hudby na svém laptopu, což mě motivovalo k přečtení několika radioamatérských článků. Technologie mne zaujala natolik, že jsem se rozhodl zabývat danou problematikou více do hloubky. V rámci mé práce bych se rád zaměřil nejen na teoretickou problematiku konceptů SDR, ale i na uvedení příkladů využití digitálního rádia v praxi, například při řešení automatizačních úloh, kde má tato technologie poměrně slibnou budoucnost. Cílem mé práce je vydat automatizační nástroj jak pro offline, tak pro online klasifikaci druhu rádiového provozu.

2 Softwarově definované rádio

Pojem Softwarově definovaného rádia, často též zkracovaného jednoduše zkratkou SDR, dnes zná téměř každý radioamatér. Ale jak vlastně SDR funguje a čím se liší od běžného rádia? Dalo by se říct, že odpověď je poměrně jednoduchá. Na rozdíl od klasického přijímače nebo vysílače, používajícího pro zpracování signálů složitý analogový obvod, se SDR raději spoléhá na moderní výpočetní techniku v podobě výkonného počítače a softwaru. Analogově digitální (A/D) převodník výpočetního zařízení se stará o vzorkování analogového, komplexního signálu přicházejícího z přijímače. Získaný digitální signál je následně možné zpracovat pomocí programu. Tato myšlenka umožňuje maximální minimalizaci hardwarové části samotného rádia. Rozměry levnějších zařízení vhodných pro příjem digitálního televizního a běžného analogového radiového vysílání jsou srovnatelné s velikostí většího flash disku, k němuž je na straně jedné připojena anténa a na straně druhé se nachází počítač. SDR přijímač/vysílač s propracovanější obvodovou architekturou je pak o něco větší.


Koncept SDR technologie je svým způsobem revoluční a důvodů je hned několik. Asi nejvýznamnější výhodou, zejména pro začínající radisty, je razantní rozdíl v ceně. Ta je díky menšímu počtu použitých součástek o řád až dva nižší, než je tomu u konkurenčních, robustních, analogových zařízení. Výpočetním mozkiem celé SDR stanice je vždy software umístěný na počítači uživatele. Program lze jednoduše aktualizovat a v případě, že nám nevyhovuje, velice snadno nahradit. Metody zpracování digitálního signálu používané v rámci SDR aplikací jsou z technického i matematického hlediska dokonalé. Na rozdíl od vysokofrekvenčních obvodových prvků nemají na výsledek žádný negativní vliv. Neznehodnocují zpracovávaný signál žádným přidaným tepelným šumem. Jediným omezením jsou matematické a fyzikální zákony společně s možnostmi A/D převodníku a použitého tuneru. Zmínit lze také zjednodušené nahrávání přijatých dat v nejrůznějších souborových formátech, jako je například WAV, či binární reprezentace signálu.

SDR technologie však má také své nevýhody. Jedním z nejčastějších omezení je velmi malá šířka pásma. Například u zařízení FanCube dongle, populárního po celém světě, se uživatelé musí spokojit s pouhými 192 kHz. Nejlevnější dostupný čip RTL2832U je schopen zpracovávat až 2,8 MHz, avšak má pouze osmibitové rozlišení a malý frekvenční rozsah. Na druhou stranu existují i širokopásmové SDR přijímače umožňující duplexní příjem i vysílání, avšak jsou několikanásobně dražší než zmiňovaný FanCube dongle a s cenou obyčejného RTL2838U se nedají vůbec srovnávat. Jedná se například o zařízení HackRF One či BladeRF. Další nevýhodou může být nespolehlivost používaného softwaru, který je často vyvíjen nadšenci. Problém nastává rovněž v nevalném zabezpečení celého systému. Slabší počítače pak mohou trpět nedostatkem výpočetního výkonu při práci, která vyžaduje rychlé přenosy dat. Jedním z hlavních stavebních kamenů, nezbytných pro efektivní práci s SDR, je zvuková karta s dostatečným dynamickým rozsahem¹. Většina dnešních zvukových karet je však pro tyto účely naprosto postačující. [3]

¹ Zvuková karta se jako A/D převodník používá pouze u levnějších zařízení



Obrázek 1: Metoda přímé digitální konverze v SDR topologii



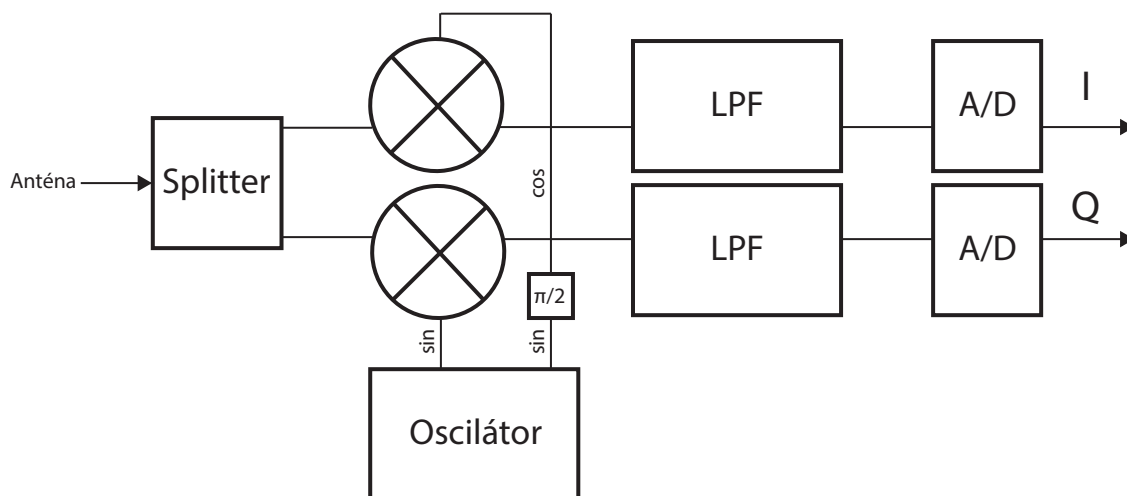
Obrázek 2: Analogové směšování do základního pásma v SDR

2.1 Koncepty SDR a princip jejich fungování

Principem každého SDR přijímače, popřípadě vysílače, je přímá konverze pásma a následný převod signálu pomocí A/D převodníku do počítače. Jednotlivé koncepty se v podstatě liší pouze tím, kdy datový tok digitalizují. Základní topologie SDR, zobrazená na obrázku 3, z níž vycházejí i všechny současné modely, využívá jednoduchého, kvadraturního směšování přijatého, širokopásmového signálu s vlnou generovanou lokálním oscilátorem, který je uživatelem naladěn na požadovanou frekvenci nosné příslušné rádiové stanice. [3]

Vraťme se na chvíli zpět a podívejme se na vývoj SDR topologií úplně od začátku. Prvním pokusem o převod výpočetních úkonů spojených s příjmem signálu na software bylo využití čisté přímé digitální konverze (DDC) v podobě schématu 1. Toto řešení je na první pohled nejvíce omezeno možnostmi A/D převodníku, neboť klade velké nároky na vzorkovací frekvenci a dynamický rozsah. Dochází také ke zbytečnému zatížení výpočetní kapacity počítače. [3, 19]

Dalším mezistupněm ve vývoji SDR přijímačů je využití přímého analogového směšování do základního pásma, realizovaného pomocí schématu 2. Myšlenka v podstatě vychází z principu původního DDC, ale počítá již s využitím lokálního, analogového oscilátoru pro převod širokopásmového signálu do základního pásma, čímž značně snižuje požadavky na A/D převodník. Hlavním nedostatkem tohoto řešení je nezbytnost softwareově řešit výskyt obou postranních pásém původního signálu ve frekvenčním spektru. Konkrétně v příkladu zapojení uvedeném na obrázku 2 se signál po vzorkování objeví na frekvenci 1 kHz a jeho obraz pak na -1 kHz. [19]



Obrázek 3: Základní topologie obvodu SDR přijímače

Rozeberme si teď detailněji dříve zmíněné schéma 3. Jedná se o takzvaný kvadraturní vzorkovací směšovač, který funguje na principu komplexní reprezentace signálu. Přijatý širokopásmový signál z antény je pomocí rozdělovače vyveden do dvou separátních větví obvodu. V každé z nich se nachází směšovač, který má na vstupu náš rozdělený signál. Druhým vstupem je vždy signál z lokálního oscilátoru, vytvářející sinusové vlnění o frekvenci nosné naladěné rádiové stanice. Do násobičky, nacházející se ve spodní větvi, přichází na druhý vstup ona sinusoida bez jakékoliv změny. Naopak před tím, než je signál z oscilátoru přiveden do horní větve, dochází k posunu jeho fáze o devadesát stupňů. V případě uvedeném na obrázku tedy vzniká ze sinu cosinus. Směšovače zajistí, že signál v horní větvi je o půl periody zpožděný oproti signálu ve větvi dolní. Oba spojitě signály projdou skrz dolní propust', kde je odfiltrován nežádoucí šum. Jako poslední se dostává ke slovu zvuková karta počítače, která pouze navzorkuje analogový signál a předá ho softwarové části rádia k dalšímu zpracování. Oproti původnímu, jednoduchému, analogovému směšovači dokáže tato topologie úplně odstranit nežádoucí postranní pásma. Na vstupu počítače tak dostáváme kýžený digitální, komplexní I/Q signál, popsany v kapitole 3. Předchůdcem tohoto řešení byl kvadraturní směšovač, jehož schéma je prakticky totožné. Jediným rozdílem oproti novějšímu modelu je, že starší typ neměl na výstupu analogové části signál v komplexní podobě. Převedení komplexního signálu na analogový bylo dříve dosahováno opětovným fázovým posuvem signálu ze spodní větve obvodu o devadesát stupňů a následným sečtením se signálem přicházejícím z horní větve. [3, 16, 19]

2.2 Omezení a rizika SDR technologie

Softwarově definované rádio je obecně velice univerzální a jeho využití je téměř neomezené. Nicméně i přes relativně příznivou cenu by byla jeho instalace i údržba v mnoha

specifických případech zbytečně drahá. Jako konkrétní příklad lze uvést svět integrovaných systémů využívající bezdrátové přenosy k realizaci nejrůznějších úkonů. Například pro otevírání vrat či odemykání auta se nejčastěji používají jednoduché speciální integrované obvody (ASIC), které jsou navrženy tak, aby při co nejnižších nákladech řešily konkrétní problém. V případě otevírání vrat nebo brány je to přenos přesně daného typu signálu mezi vysílačem a přijímačem. Je zřejmé, že velké množství na první pohled odlišných produktů, které nalezneme na trhu, má nějakou formu dálkového ovládání. Tu lze ve většině případů řešit stejným nebo velmi podobným integrovaným obvodem. Díky vysoké poptávce je výrobní cena takových součástek oproti SDR přijímačům/vysílačům extrémně nízká.[16]

Specifická funkcionality integrovaných systémů nevyžaduje příliš komplexní řešení, jako je tomu v případě SDR. Postačuje, když ASIC dokáže zpracovat jediný typ signálu, který je navíc často úzkopásmový. V případě SDR je tomu přesně naopak. Množství nejrůznějších modulátorů, demodulátorů a filtrů navyšuje složitost řešení, celkové nároky na vývoj systému i potřebný rozpočet. S problematikou složitosti je úzce spjata otázka údržby. Integrovaný obvod dokáže fungovat několik let bez nutnosti restartu při zanedbatelné spotřebě elektrické energie. To platí i při realizaci samotného přenosu. SDR je nutné připojit na zvukovou kartu s velkým dynamický rozsahem. Nesmíme přitom zapomenout na veškerý hardware nacházející se mezi anténou a A/D převodníkem na zvukové kartě. Ten je samozřejmě také potřeba napájet. Ve výsledku lze říci, že SDR spotřebuje při vykonávání stejné práce jako ASIC až desetkrát více energie.[16]

Výše zmíněná komplexnost SDR je největším záporem v otázce širšího, komerčního nasazení SDR v porovnání s ASIC obvody. Kromě několikanásobně vyšších požadavků na technický návrh řešení lze počítat se složitější specifikací funkcionality, která musí umožnit i budoucí implementaci nově vzniklých druhů radiového provozu. Z manažerského hlediska pak může být náročnost vývoje vnímána jako zdroj zvýšeného množství rizik.[16]

Mnoho odpůrců SDR se pozastavuje nad bezpečnostními riziky a spolehlivostí, které s sebou propojení rádia s počítačem přináší. Pokud by byl úspěšně napaden počítač v roli ústředny, zabezpečující datové spojení skrz SDR, mohlo by dojít k nežádoucímu úniku přenášených informací nebo dokonce k poškození hardwaru. V případě spolehlivosti softwaru pak narážíme na problém, jak efektivně otestovat všechnu funkcionality v tak komplexním systému. Jestliže koncept SDR je založen na univerzálnosti a možnosti adaptace systému na nové druhy provozu, pak jen velmi těžko vyzkoušíme všechny možné kombinace různých druhů modulací, vzorovacích frekvencí, modulačních a přenosových rychlostí.[16]

3 Modulace a komplexní signál

Ve světě moderního, softwarově definovaného rádia se v žádném případě nelze vyhnout práci s komplexními signály. Může za to současně běžně používaná topologie SDR přijímačů, která je blíže rozebrání v podkapitole 2.1. Prakticky se pojem I/Q dat objevuje již na samém začátku přijímacího řetězce radiové stanice. Mimo jiné operace zde totiž dochází k rozdělení přijatého analogového signálu proudícího směrem od antény. Abychom jej však zvládli zpracovat, musíme nejprve pochopit, jak spolu souvisí reálná a imaginární složka každého vzorku. Co z nich lze vlastně vyčíst a jak se dají využít při procesu klasifikace druhu modulace?

3.1 Reálná a imaginární složka komplexního signálu

Matematický popis komplexního signálu jasně říká, že je vždy složen ze dvou složek, reálné a imaginární. Máme-li k dispozici diskretní vzorky signálu typu I/Q, musíme se na ně dívat jako na komplexní čísla, jejichž posloupnost v čase reprezentuje původní signál. Pro práci s nimi je nezbytné použít Gaussovu rovinu. Reálná část vzorku, tedy I, nese informaci o okamžité hodnotě amplitudy původního signálu a obvykle se značí na vodorovné ose. Imaginární část je zobrazena na svislé ose Gaussovy roviny jakožto okamžitá hodnota signálu Q, který je zpožděný o čtvrt periody oproti reálnému I. Na obě složky se lze tedy dívat i nezávisle jako na dva reálné signály, lišící se pouze fázovým posunem o $\frac{\pi}{2}$. Matematické vyjádření komplexního signálu včetně jeho jednotlivých bodů vychází z trigonometrie a definice komplexních čísel. Rovnice pro vzájemný vztah amplitudy reprezentované proměnnou A, fáze vyjádřenou ϕ a reálné/imaginární (I/Q) složky je uvedeno v rovnicích (1), (2). Goniometrický vztah mezi složkami lze najít v rovnici (3). [5, 13, 19]

$$I = A \cdot \cos(\phi) \quad (1)$$

$$Q = A \cdot \sin(\phi) \quad (2)$$

$$I + j \cdot Q = A \cdot (\cos(\phi) + j \cdot \sin(\phi)) \quad (3)$$

Díky hodnotám neseným oběma složkami signálu již dokážeme pomocí trigonometrie a Pythagorovy věty snadno dopočítat veškeré informace, které nás mohou zajímat. Musíme však mít na paměti, že všechny vzorky budou vždy ovlivněny nežádoucím rušením různého druhu. Z tohoto důvodu je před samotným zpracováním nutné oddělit signál od šumu a zlepšit tak jeho kvalitu měřitelnou pomocí poměru signál šum (SNR). Způsob měření je popsán v kapitole 4. Jednotlivé vztahy a rovnice pro výpočet základních, signálových charakteristik jsou popsány níže.


3.2 Okamžitá amplituda

Definice 3.1 Okamžitá amplituda v diskretním bodě komplexního, digitálního signálu je definována jako:

$$A(n) = \sqrt{I(n)^2 + Q(n)^2} [V] \quad (4)$$

kde $I(n)$ je hodnota reálné složky komplexního čísla, $Q(n)$ je hodnota imaginární složky komplexního čísla a $A(n)$ je okamžitá amplituda v bodě n . [13]

Výpočet hodnoty okamžité amplitudy se postupem nijak neliší od vzorce pro výpočet absolutní hodnoty komplexního čísla. Vliv modulace na okamžitou amplitudu je zřejmý. Použijeme-li například čistou formu AM či ASK, bude se její hodnota v čase měnit, naopak fáze i frekvence zůstávají stále stejné.



Obrázek 4: Vztah mezi I/Q vzorky a okamžitou amplitudou


3.3 Okamžitá fáze

Definice 3.2 Okamžitá fáze v diskretním bodě komplexního, digitálního signálu je definována jako:

$$\phi(n) = \tan^{-1} \left(\frac{I(n)}{Q(n)} \right) [rad] \quad (5)$$

kde $I(n)$ je hodnota reálné složky komplexního čísla, $Q(n)$ je hodnota imaginární složky komplexního čísla a $\phi(n)$ je fáze v bodě n . [13]

Okamžitá fáze v daném diskretním bodě odpovídá argumentu komplexního čísla v goniometrické podobě. Musíme však pamatovat na to, že funkce \tan^{-1} je sice definována pro všechna reálná čísla, avšak obor hodnot je v intervalu $-\frac{\pi}{2}; \frac{\pi}{2}$ radiánů a vypočtené hodnoty tak nezohledňují k-násobky π . To znamená, že pokud chceme získat skutečný průběh fáze v čase, musíme provést její rozbalení [10]. Ke změně této charakteristiky v čase dochází při použití modulací, přenášejících informace úpravou fáze jako je například Phase shift keying (PSK), či fázová modulace. Změnu parametru však způsobuje i použití FM či FSK, což do jisté míry znesnadňuje jejich oddělení od čistě fázových forem rádiového provozu. [13]



Obrázek 5: Vztah mezi I/Q vzorky a okamžitou fází

3.4 Okamžitá frekvence

Definice 3.3 Okamžitá frekvence v diskretním bodě komplexního, digitálního signálu je definována jako:

$$f(n) = \frac{1}{2\pi} \cdot \frac{d\phi(t)}{dt} [Hz] \quad (6)$$

kde $\phi(t)$ je funkce okamžité fáze v čase uvedená v radiánech a $f(n)$ je výsledná frekvence v bodě n . [13, 20]

Konečně okamžitou frekvenci, často přesněji označovanou také jako fázová rychlost, lze vypočíst derivací funkce fáze podle času pomocí rovnice (6). Diskretní signál nelze derivovat, ekvivalentní operace je difference po sobě jdoucích bodů fáze. Změnou hodnoty


okamžité frekvence v čase se vyznačují veškeré frekvenční modulační. Nicméně výše uvedený vzorec není v praxi příliš využíván, neboť je ovlivněn $k\pi$ nepřesnostmi obsaženými v zabalené fázi. Proto se častěji využívá metody uvedené v rovnici (7). [14, 20]

Definice 3.4 Okamžitou frekvenci v diskretním bodě komplexního, digitálního signálu lze také definovat jako:

$$f(n) = \frac{1}{2\pi} \cdot \frac{I(n) \cdot Q'(n) - I'(n) \cdot Q(n)}{I(n)^2 + Q(n)^2} [Hz] \quad (7)$$

kde $I(n)$ je reálná složka komplexního čísla, $Q(n)$ hodnota imaginární složky, $I'(n)$, $Q'(n)$ označují diferenci mezi sousedními reálnými a imaginárními hodnotami a $f(n)$ je okamžitá frekvence v bodě n .

Pro určení okamžité frekvence existuje i řada dalších metod. Lze například využít FIR filtrů nebo sledování průchodů nulou. [14]



Obrázek 6: Vztah mezi I/Q vzorky a okamžitou frekvencí

4 Zarušení signálu

Každý signál, který je přenášen libovolným přenosovým médiem, ať už jde o vzduch, optické nebo metalické vedení, je do určité míry ovlivněn nežádoucím rušením označovaným jako šum. Ten může způsobovat zkreslení užitečného signálu, či dokonce úplně znemožnit jeho příjem. Problematiku rušení do jisté míry řeší různé modulační techniky zvyšující odolnost užitečného signálu. Ačkoliv šum nelze žádným způsobem úplně eliminovat, můžeme efektivně minimalizovat jeho vliv na straně přijímače. Abychom toho byli schopni dosáhnout, je nezbytné si uvědomit jaké druhy šumu existují, čím jsou charakteristické, jaké problémy mohou způsobovat a mít povědomí o metodách pro jeho minimalizaci. Společnými charakteristickými vlastnostmi všech druhů šumu je jejich malá korelace s užitečným signálem, nízký výkon a vysoká frekvence. Velmi užitečným parametrem je odstup signálu od šumu, anglicky též Signal to noise ratio (SNR), indikující rozpoznatelnost užitečného signálu od šumu. Matematická definice SNR je uvedena níže. [1, 5, 7]

$$SNR = 10 \cdot \log_{10} \left(\frac{P_s}{P_n} \right) [dB] \quad (8)$$

Čím je poměr vyšší, tím lépe je signál od šumu rozeznatelný, přičemž akceptovatelné minimum je $SNR = 2$. Je zřejmé, že s klesajícím SNR lze očekávat větší výkyvy v amplitudě, frekvenci i fázi a tím pádem nižší přesnost klasifikace použité modulace. Nejméně rezistentní vůči šumu jsou přitom provozy založené na amplitudových modulačních principech. [18]

4.1 Bílý šum

Charakteristickým znakem bílého šumu je jeho náhodnost, ploché výkonové spektrum a konstantní, nízká, spektrální, výkonová hustota ve stejné šířce pásma na jakékoliv frekvenci. Bílý šum poměrně dobře popisuje situaci v každém přenosovém kanále, neboť je vždy přítomen a jeho výskyt je oproti ostatním druhům rušení majoritní. Je nutné podotknout, že samotný bílý šum není nutně svázán s konkrétním rozdělením hustoty pravděpodobnosti. Můžeme sem zařadit např. tepelný šum, nebo Gaussovský šum (AWGN). [1, 15, 18]

4.2 Barevný šum

V podstatě se jedná o jakýsi doplněk bílého šumu. Je širokopásmový a na rozdíl od bílého šumu nemá ploché výkonové spektrum. Rovněž je většinou nízkofrekvenční. Existuje mnoho variant, nejčastěji jde např. o růžový či hnědý šum. [1, 15]

4.3 Impulzní šum

Tento druh šumu se v užitečném signálu projevuje jako náhlý, sporadický nárůst jeho výkonu trvající po náhodně dlouhou dobu, v praxi dosahující několika desítek milisekund.

Jeho nebezpečí nespočívá pouze v degradaci užitečného signálu, ale může rovněž zapříčinit trvalé poškození sluchu. [1, 15]

4.4 Metody minimalizace šumu

Jak již bylo řečeno šum, který jednou ovlivní přenášený signál, už nelze nikdy úplně odstranit. Metody sloužící k jeho minimalizaci se rozdělují na lineární a nelineární filtry. [18]

4.4.1 Lineární filtry

Pro lineární způsoby filtrace je charakteristické, že výsledné hodnoty vznikají pomocí lineární kombinace vstupních hodnot. S jakoukoliv změnou na vstupu vždy dojde také ke změně na výstupu filtru.

Dolní propust' nepropouští signály vyšších frekvencí. Pokud je filtr správně nastaven, pak nedochází k degradaci signálu.

Horní propust' nepropouští signály nižších frekvencí. I zde je podstatné dobré nastavení filtru.

Pásmová propust' propouští pouze signály, jejichž frekvence se nachází mezi horní a dolní mezí filtru. V podstatě jde o kombinaci horní a dolní propusti.

Klouzavý průměr se používá pouze u diskrétních signálů. Hodnota amplitudy aktuálního vzorku je nahrazena průměrem jeho nejbližších x předchůdců. Pro lepší výsledky lze použít vážený, klouzavý průměr. Metoda průměrování vede k degradaci ostrých hran.

4.4.2 Nelineární filtry

Narozdíl od lineárních filtrů je nelineární filtrování nepřímou závislostí na vstupních datech. Není nutně pravdou, že sebemenší změna na vstupu ovlivní i výstup. Vždy záleží na charakteru změny, která v datovém proudu proběhla.

Mediánový filtr, podobně jako lineární metoda průměrování, vybere nejbližších x předchůdců daného vzorku a jeho hodnotu nahradí mediánem vybraným z dříve seřazených předchůdců. Degraduje ostré hrany signálu.

Prahování koeficientů vlnkové transformace je nelineární metoda využívající vlnkové transformace signálu. Po výpočtu transformace jsou hodnoty s nižší než prahovou hodnotou vyřazeny a následně je signál převeden zpět do vstupní podoby. Nedochází k negativnímu ovlivnění hran.

5 Rešerše možných řešení

Odborníci se tématem softwarového rádia zabývají již od první poloviny devadesátých let. Velmi brzo se objevily hlasy volající po potřebě automatické detekce druhu přijímaného signálu. Ozývaly se zejména ze strany armádních složek, avšak zájem rychle prosákl i do soukromého sektoru. Inženýři si velmi dobře uvědomovali důležitost takového nástroje. Schopnost přesně určit typ použité modulace, společně se získanými, detailními, technickými informacemi o signálu by umožnil nejen jeho odposlech, ale také efektivní výběr metody rušení jakéhokoliv bezdrátového přenosu nebo opětovné rozkódování rušeného signálu. Avšak nesmíme zapomínat, že automatické klasifikátory modulací (AMC) mají velký význam pro rádiové vysílání v civilní i korporátní sféře dodnes všude tam, kde se vyskytují adaptivní modulační systémy. Lze zmínit například moderní datové sítě mobilních operátorů. Může-li si vysílač v závislosti na měnících se podmínkách v přenosové cestě sám vybrat druh modulace, aby optimalizoval kvalitu spojení, pak musí být přijímací strana schopna dynamicky se měnící modulaci rozeznat. [5, 2]

Asi největšími průkopníky se v průběhu let stala dvojice vědců Azzouz a Nandi [7]. Vydali značné množství publikací a mimo jiné jako první na světě představili odborné veřejnosti myšlenku klasifikátoru založeného na zkoumání jednotlivých statistických znaků modulovaného signálu. Na jejich práci později stavěli své výzkumy také mnozí další. Díky tomu vznikla v průběhu let celá řada algoritmů, jejichž úkolem je řešit tento klasifikační problém. Můžeme je rozdělit do dvou základních skupin v závislosti na přístupech, na nichž jsou postaveny: [2, 4]

- Využití pravděpodobnostních funkcí
- Zkoumání vlastností digitálního signálu

Výše zmíněné skupiny přístupů obsahují konkrétní rozhodovací techniky, uvedené v tabulce 1, které jsou v praxi implementovány pomocí algoritmů. Obě skupiny metod jsou rovněž detailněji rozvedeny níže.

Výše zmíněné principy mají své výhody a omezení. Jako největší společný problém lze uvést například odolnost dané metody vůči míře šumu, jímž je signál v reálném světě vždy zkreslen. Je patrné, že s klesajícím parametrem SNR se více či méně zhoršuje přesnost jednotlivých metod. Dalším společným rysem je statistický základ dílčích výpočtů. [4] Z toho vyplývá, že při procesu klasifikace se stává vliv nežádoucích jevů důležitým faktorem, jehož výsledkem je téměř vždy vznik určitého druhu rušení zkoumaného signálu. Při návrhu je klíčová dobrá znalost o jeho vzniku, důsledcích a o možnostech minimalizace. Druhy nejběžnějšího šumu a metodiky pro jeho odstranění jsou popsány v tabulce 2.

5.1 Využití pravděpodobnostních funkcí

Většina teoretických řešení problematiky klasifikace modulovaného signálu se spoléhá na výpočet věrohodnostní funkce, což je typické pro algoritmy využívající korelaci vyššího řádu. Rovněž se lze setkat s aplikací rozdělení pravděpodobnosti jako je tomu u me-

Využití pravděpodobnostních funkcí	Zkoumání vlastností digitálního signálu
HLRT	Neuronové sítě
Korelace vyššího řádu	SVM
Kumulanty	Vlnková transformace
Prahové klasifikátory	Genetické algoritmy

Tabulka 1: Nejběžnější klasifikační techniky používané pro rozpoznání druhu modulace

Druh šumu	Možnosti potlačení	Nevýhoda
AWGN	Filtr klouzavého průměru Pásmová nebo dolní propust'	Nežádoucí zaoblení ostrých hran Ztráta užitečných vzorků
Impulsní šum	Mediánový filtr	Degradace užitečného signálu

Tabulka 2: Nejčastější druhy šumu a možnosti jejich potlačení

tody Hybrid likelihood ratio test (HLRT), viz podkapitola 5.1.1. V případě prahových klasifikátorů se pak běžně navrhuje rozhodovací proces založený na porovnávání statistických veličin. Tento přístup je dobře prověřený a spolehlivý v rámci ideálního přenosového kanálu, ve kterém je jediným nežádoucím prvkem AWGN. Značný vliv na degradaci výsledků metod mají rušivé vlivy způsobující fázové/frekvenční posuny a fading. Další nevýhodou je složitost algoritmů, starajících se o provádění dílčích výpočtů. [5, 4]

Nejběžnějšími klasifikačními technikami, které lze v tomto směru použít, jsou HLRT, korelace vyššího řádu, statistické kumulanty a prahové klasifikátory. V drtivé většině případů je na vstupu nutné uvést podrobné parametry rádiového kanálu, na němž je signál vyslán. Díky tomu nemusí být využití tohoto přístupu v praxi vždy jednoduché či efektivní. [4]

5.1.1 Hybrid likelihood ratio test (HLRT)

Technika HLRT je založena na svých dvou předchůdcích. Prvním z nich je Average likelihood ratio test (ALRT), postavený na myšlence aplikace funkce rozdělení pravděpodobnosti na neznámé parametry vstupního signálu, které jsou vnímány jako náhodné proměnné. Oproti tomu Generalised likelihood ratio test (GLRT), považovaný za opak ALRT, pracuje s faktem, že ne vždy je funkce rozdělení pravděpodobnosti použitelná, a proto parametry signálu modeluje jako neznámé konstanty. HLRT pak efektivně kombinuje oba své předky tak, aby došlo k optimalizaci finálního výstupu i složitosti výpočtu. [21]

Nejběžnějšími fyzikálně-matematickými parametry, s nimiž HLRT pracuje, jsou okamžitá hodnota amplitudy, fáze a frekvence. Na jejich základě je následně možné vypočítat další statistické veličiny.

5.1.2 Prahové klasifikátory

Prahové klasifikátory jsou úzce spojeny s HLRT metodou. Využívají téměř všechny statistické veličiny, které lze z HLRT získat. Rozhodování probíhá pomocí podmínkového stromu, kdy jsou jednotlivé veličiny porovnány s prahovou hodnotou, získanou na základě předchozích experimentů. Tento druh rozhodování je velice přesný, avšak náchylný k výskytům šumu a s ním spojeným excesům. [5, 21]

5.1.3 Korelace vyššího řádu

Korelace vyššího řádu zajišťuje lepší robustnost rozhodovacího algoritmu vůči rušivým vlivům, které se ve zkoumaném signálu nacházejí, než je tomu u dvou předchozích technik. Hlavní rozdíl je v procesu získávání parametrů signálu pomocí autokorelace n -tého řádu, díky kterému je možné odhadnout průměrnou věrohodnostní funkci. [21]

5.1.4 Kumulanty

Nejčastěji používané kumulanty n -tého řádu v AMC klasifikátorech jsou pravidelné a cyklické. Vzhledem k tomu, že kumulanty souvisí s obecným momentem, dochází při výpočtu k jejich párování v závislosti na čase. Výsledek je nakonec zkombinován ve formě výstupního kumulantu. Následný rozhodovací proces je prováděn na základě porovnání získaného kumulantu s jeho ideální hodnotou pro jednotlivé typy modulací. [21]

Tato metodika je oblíbená díky své netečnosti vůči rušení i šumu ve vstupním signálu a nízké výpočetní režii. Doporučuje se využívat kumulanty alespoň 4. řádu a vyšší, protože Gaussovský šum na ně nemá vliv. [21]

5.2 Zkoumání vlastností digitálního signálu

Využití vlastností modulovaného, číslicového signálu je založeno na prostém faktu, že každý druh modulace nese původní informaci ve změně amplitudy, fáze nebo frekvence. Při výpočtu jednotlivých statistických, matematicko-fyzikálních charakteristik využíváme právě změny těchto složek, jejichž průběh lze definovat jako funkci v čase. V praxi je tento přístup z hlediska implementace považován za jednodušší, než je tomu u výše zmíněné metody maximální věrohodnosti. Nespornou výhodou je silná odolnost algoritmu vůči nejrozličnějším druhům rušení. Za nevýhodu lze naopak považovat nižší procentuální úspěšnost samotné klasifikace. [5, 4, 21]

Obecná architektura klasifikátoru se skládá ze tří částí. První sled operací zajišťuje část řešení, označovanou jako pre-processing. V případě, že je signál na vstupu reprezentován jako reálný sled navzorkovaných hodnot, musí projít Hilbertovou transformací. Získaná I/Q data je dále nutné odrušit, nejčastěji pomocí filtrů uvedených v tabulce 2. [21]

Druhou část tvoří modul, zajišťující extrakci charakteristik signálu. Z předdefinovaných vzorců pro výpočet statistických veličin jsou získány vektory obsahující směrodatné

informace o změnách jednotlivých složek signálu v daném časovém úseku. Počet známých statistických veličin, které lze ze vstupního signálu vypočítat, může být až devět [4].

Finálním krokem je samotná klasifikace druhu použité modulace na základě vektorů získaných pomocí dříve uvedených výpočtů. Rozhodnutí lze učinit pomocí fuzzy logiky, neuronové sítě, SVM, vlnkové transformace a můžeme také využít výhod genetického programování. [21]

5.2.1 Neuronová síť

Využití neuronové sítě pro klasifikaci druhu rádiového provozu je vždy postaveno na kompromisu mezi přesností a použitelností modelu. Nejčastějšími problémy, či chybami, s nimiž se lze setkat, je špatný výběr vstupních parametrů, které mohou zpomalovat rozhodovací proces nebo dokonce znemožnit přesné určení druhu modulace. Efektivitu ovlivňuje také počet vstupních parametrů. Ten v podstatě definuje množství neuronů v první vrstvě sítě a má tak zásadní vliv na výpočetní čas. Azzouz a NandiAMRAz-zouzNandi dosáhli nejspokojivějších výsledků se čtyřmi vstupními parametry pro rozlišení analogových modulací. Pro klasifikaci digitálních modulací bylo potřeba vstupů pět. [21]

Nejjednodušším používaným typem sítě jsou víceúrovňové struktury složené z perceptronů, označované též jako Feed forward síť. Bohužel se často vyskytují problémy při jejich učení, kdy dochází k zaseknutí chybové funkce na lokálním minimu. Chybová funkce vyjadřuje s jakou přesností dokáže síť rozpoznat jednotlivé typy modulací. Hledáme tedy minimum globální nikoliv lokální. Řešením může být použití učební metody Back-propagation, zabráňující zaseknutí při hledání globálního minima pomocí takzvaných Bias neuronů. Druhým populárním typem sítě je Radial basis function (RBF), která má při učení lepší vlastnosti.[9, 21]

5.2.2 Support vector machine (SVM)

Technologie SVM je zajímavou alternativou k neuronovým sítím. Hlavní výhodou je potlačení nešvarů, vznikajících v průběhu učení neuronové sítě, jako je například běžný problém lokálního minima chybové funkce. Nabízejí nižší výpočetní složitost nezávislou na počtu vstupních parametrů, což má za následek menší rozhodovací čas s nižšími nároky na výkon. Na druhou stranu se nemění vliv typu vstupních parametrů na výsledek klasifikace. [21]

SVM rozhoduje na základě nalezení optimální nadroviny, která rozděluje dvě třídy do poloprostorů podle určitých parametrů. Nejlepším kandidátem je vždy nadrovina s největším minimálním odstupem nejbližších bodů z obou poloprostorů. Z toho vyplývá, že můžeme získat pouze binární hodnotu podle toho, do jakého poloprostoru právě zkoumaný prvek vstupního vektoru patří. Z hlediska složitosti je to obrovská výhoda. Použitelnost v AMC je čistě rekurzivní, kdy například nejdříve rozhodneme, zda se jedná o modulaci digitální či analogovou, následně zkoumáme zda signál nese informaci v amplitudě, frekvenci, fázi, či v jejich kombinaci. [21]

5.2.3 Vlnková transformace

Metoda klasifikace založená na výpočtu vlnkové transformace našla své uplatnění v systémech vyžadujících určení druhu modulace v reálném čase, jako jsou například adaptivní demodulátory. Určení druhu rádiového vysílání je založeno na zkoumání přechodů v amplitudě, frekvenci a fázi cyklostacionárních charakteristik modulovaného signálu. Tyto změny se projevují jako výrazné špičky a na základě jejich velikosti/kombinace je možné vyvodit patřičné závěry. [21]

5.2.4 Genetické programování

V rámci klasifikačních problémů jsou genetické algoritmy považovány stejně jako SVM za binární. Modulované signály jsou hierarchicky řazeny do klastrů podle jejich okamžitých konstelačních diagramů. V praxi se rozhodování převádí na klasifikaci do více tříd s využitím algoritmu k-tého nejbližšího souseda. [21]

Genetické algoritmy našly uplatnění nejen ve formě klasifikačních metod. Za nejvýznamnější přínos je považována implementace výběru nejlepších vstupních parametrů pro SVM a neuronové sítě, jejichž rozhodovací schopnosti jsou úzce spjaty s konkrétním typem vstupu. [21]

5.3 Přehled existujících implementací

Prvním praktickým cílem práce, ještě před započítím samotného vývoje vlastní aplikace, bylo prozkoumat dostupnost softwaru, nabízející stejnou či podobnou funkcionalitu. Při hledání jsem narazil na tři nejpravděpodobnější konkurenty, přičemž používání každého z nich je v současné době vázáno komerční licencí.

5.3.1 NI LabView - AMC-CSD

Prvním vážným kandidátem je aplikace vyvinutá v dobře známém programu LabView, který nabízí užitečné nástroje pro virtualizaci nejrůznějších elektrotechnických zařízení a hodí se i pro práci se signály. Ačkoliv se jedná o open source řešení, je zřejmé, že k jeho využívání je zapotřebí placená verze LabView, na němž produkt staví. Další nevýhodou je nutnost instalace externího balíku, nabízejícího veškeré modulační bloky.

Při rozpoznávání modulací je uživatel omezen na čtyři nejpoužívanější typy digitálního provozu (BPSK, QPSK, BFSK, MSK). Předpokladem je funkční hardware komunikující s LabView. Produkt je možné vyzkoušet zdarma pouze s využitím neplacené studentské licence, kterou firma National Instruments nabízí na svém webu.

5.3.2 Matlab - AMC-Toolbox

Podobně jako AMC-CSD je i knihovna AMC-Toolbox volně stažitelná z internetu, avšak pro její spuštění je potřeba nainstalovat také prostředí Matlab, které je šířené pod placenou licenci a bohužel nenabízí volný přístup ani v rámci zkušební verze či studentské licence. Zdrojový kód knihovny je volně dostupný pouze v zašifrované podobě souborů,

což znemožňuje jejich spuštění například v open source programu Octave. Dle nezašifrovaného demo souboru je však možné říci, že pro řešení klasifikace typů modulací využívá AMC-Toolbox pravděpodobnostní metody. Podporované typy provozů jsou dvou až čtyř stavové verze PAM a PSK, dále pak 4 - 64QAM.

5.3.3 Andro - AMC

Nakonec poslední a trochu netradiční řešení má na svědomí americká firma Andro, spolupracující s několika univerzitami v USA. Jejich řešení využívá bezdrátovou senzorickou síť pro sběr informací, podle nichž se následně určuje druh použité modulace. Toto řešení jsem bohužel neměl možnost otestovat. Podle dostupných informací je jeho hlavní výhodou zejména cena.

6 Praktická realizace v jazyce C#

V rámci praktického přínosu práce bylo rozhodnuto vyvinout aplikaci, určenou pro automatickou detekci druhu radiového provozu, v programovacím jazyce C#. Samotná klasifikace je realizována vícevrstvou, neuronovou sítí typu Feed forward, jejímiž vstupy jsou základní statistické charakteristiky vstupního signálu, jako je například směrodatná odchylka absolutní hodnoty centrované nelineární složky fáze nebo míra symetrie frekvenčního spektra. Pro realizaci uživatelského rozhraní byla využita technologie Windows presentation foundation (WPF) s návrhovým vzorem Model, view, viewmodel (MVVM). Prezentační grafy obstarává volně dostupná knihovna OxyPlot. Neuronová síť je implementována pomocí známé open source knihovny Encog², která nabízí široké spektrum možností strojového učení. Aplikace podporuje filtrování vstupních dat pomocí diskrétní, pásmové propusti realizované pomocí filtru s konečnou impulsní odezvou (FIR).

Řešení je rozděleno do tří vzájemně provázaných projektů. Prvním z nich je RTAD.Core, jenž je zodpovědný za veškeré matematické výpočty, filtrování, transformace a čtení dat, které jsou vykonávány nad vstupním komplexním signálem.

Druhý projekt, RTAD.UserInterface, jak již vyplývá z jeho názvu, řeší problematiku uživatelského rozhraní programu pomocí již dříve zmíněné MVVM technologie. Umožňuje pohodlnou specifikaci všech vstupních parametrů, nezbytných pro klasifikaci druhu modulace. Součástí implementace je i validace hodnot vkládaných uživatelem.

Poslední částí je malá konzolová aplikace s názvem RTAD.TrainingTool, sloužící ke snadnému vytvoření, učení, následné validaci a serializaci zvoleného modelu neuronové sítě. Model je uložen v binární podobě společně s třídou NormalizationHelper. Ta usnadňuje práci s daty, které je vždy potřeba na vstupu použitého modelu normalizovat tak, aby s nimi neuronová síť dokázala pracovat.

Výše uvedené projekty doplňuje knihovna Encog, jejíž zdrojové kódy bylo potřeba stáhnout, neboť obsahovaly chybu bránící v serializaci vytvořených modelů neuronových sítí.

6.1 Vstup

Aplikace je schopna pracovat se soubory obsahujícími komplexní vzorky signálu v binární podobě s maximální vzorkovací frekvencí 450kHz. Soubor se skládá ze střídajících se 32-bitových čísel typu float. Liché hodnoty reprezentují reálnou složku komplexního čísla neboli I signál. Naopak sudé pozice jsou nositeli imaginární části, tedy Q signálu.

Počet načítaných vzorků je přímo spjat s velikostí okna, nastavitelnou přes hlavní okno programu. Vzhledem k tomu jak jsou jednotlivé složky v binární podobě reprezentovány, je jasné, že algoritmus vždy načte dvojnásobek délky okna, kdy dvě za sebou jdoucí hodnoty reprezentují jeden komplexní vzorek. Kvůli optimalizaci nedochází v rámci samotného čtení jednotlivých vzorků k žádným dalším výpočtům přenášených informací, které nejsou nezbytné pro detekování užitečného signálu v právě zpracová-

²Dokumentace knihovny Encog: <http://www.heatonresearch.com/encog/>

vaném okně. Veličiny jako jsou okamžitá fáze či frekvence jsou extrahovány až v případě úspěšné detekce užitečného signálu v načtených datech popsané níže v podkapitole 6.3. Jediným úkonem, který může být v závislosti na konfiguraci při čtení ze souboru vykonáván, je aplikace filtru s konečnou impulsní odezvou (FIR) typu pásmová propust' realizovaná pomocí konvoluce.

6.1.1 Simulace a záznam vstupních dat

Aby bylo při vývoji možné průběžně testovat správnou funkcionalitu dílčích částí programu, například čtení binárních dat, algoritmus pro diskretní Fourierovu transformaci (DFT) v komplexní podobě nebo rozbalení fáze, bylo zapotřebí získat odpovídající vstupní data. Bez nich by se nakonec neobešel ani proces učení a validace modelu neuronové sítě.

Jako jedna z možných alternativ se jeví odchycení běžného rádiového provozu pomocí SDR přijímače a GNU Radia. Řešení vyžadovalo sestavení jednoduchého programu, schopného prostřednictvím SDR hardwaru zachytit standardní rádiové vysílání. K tomu postačilo grafické rozhraní GRC obsahující všechny potřebné moduly. Za velkou nevýhodu tohoto přístupu lze považovat fakt, že získaná data jsou vždy do určité míry ovlivněná šumem, což by se mohlo negativně projevit na vytváření modelu neuronové sítě. Efektivní možností jak šum odfiltrovat, bylo použít pásmovou propust', nicméně ani to nevedlo k úplnému odstranění rušení. Nalezení všech druhů modulací, které má aplikace podporovat ve frekvenčním spektru a jejich správná identifikace by byla rovněž obtížná.

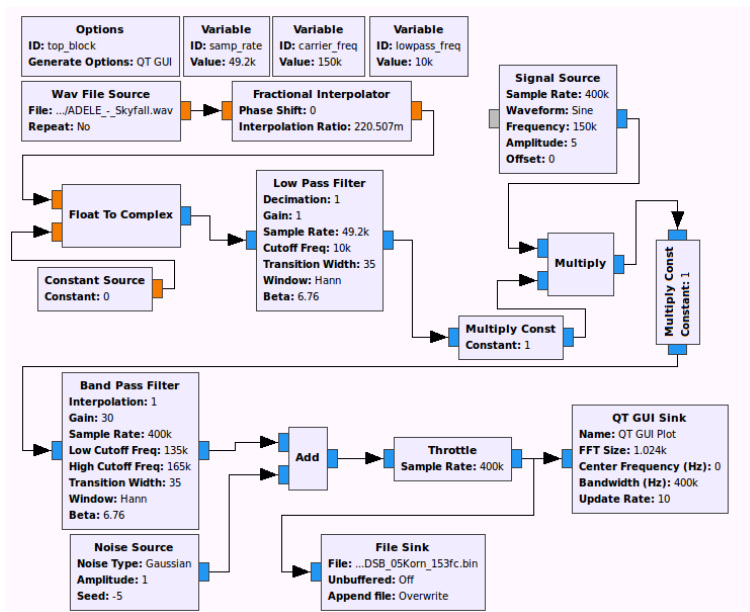
Druhá možnost, opět založená na využití výše zmíněných GRC modulů, spočívala ve vytvoření několika programů, umožňujících simulaci jednotlivých modulací. Výhodou byla absolutní kontrola nad modulačním, nosným i modulovaným signálem a šumem, avšak za cenu celkově větší časové náročnosti. Viz podkapitoly 6.1.2, 6.1.3.

Nejprve byl kladen větší důraz na řešení založené na simulování modulací. V průběhu testování se však ukázalo, že bude nezbytné vytvořit také přijímač skutečného rádiového provozu, aby bylo možné vyzkoušet úspěšnost klasifikace na reálných datech.

6.1.2 Schémata analogových modulátorů

Vstupem všech analogových modulátorů je vždy spojitý modulační a nosný signál. V GRC lze oba vstupy uměle vygenerovat pomocí bloku Signal source. Zatím co využití tohoto modulu pro vytvoření nosné vlny je zcela na místě, pro modulační signál je k dosažení co nejlepší podobnosti vůči datům, která jsou přenášena v běžném rádiovém provozu, mnohem vhodnější sáhnout po souboru obsahujícím například libovolnou písničku či mluvené slovo. Z tohoto důvodu je u všech níže uvedených simulací na vstup přiveden audio soubor ve formátu WAV. Následně se z důvodu omezení šířky pásma aplikuje na vstupní signál filtr typu dolní propust' a dále již probíhá proces modulace dle jejího typu. Výsledný komplexní signál je nakonec uložen do binárního souboru.

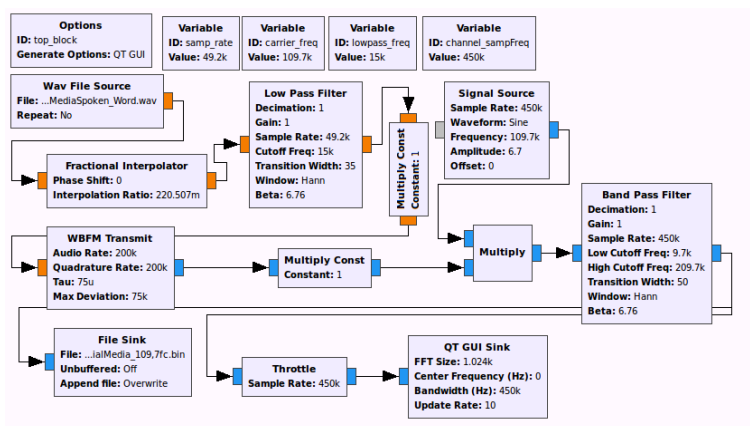
Amplitudový modulátor, uvedený na obrázku 7, je jedním z nejjednodušších vůbec. Modulační signál moduluje nosnou vlnu pomocí násobičky. Po této operaci následuje omezení šířky pásma dle zvoleného typu provozu. V případě běžného AM provozu platí



Obrázek 7: Schéma AM modulátoru

rovnice 9. Použijeme-li pouze jedno postranní pásmo, pak je potřebná šířka pásma poloviční.

$$BW_{AM} = 2f_{max} \quad (9)$$

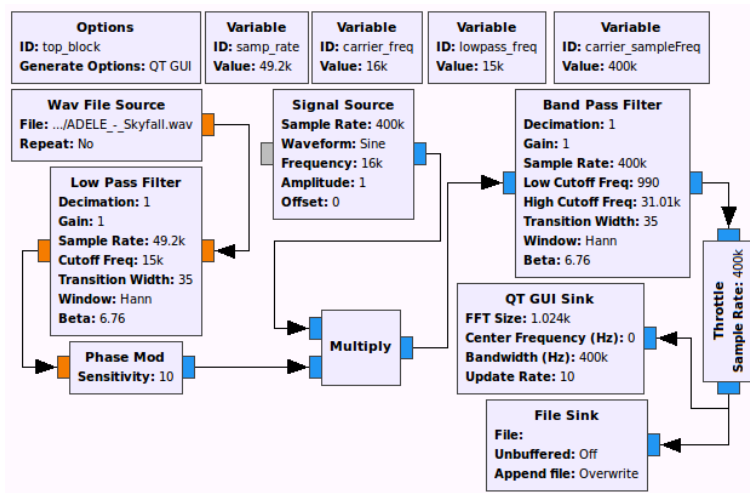


Obrázek 8: Schéma FM modulátoru

Širokopásmová frekvenční modulace je v GRC rozhraní zastoupena samostatným modulem pod názvem Wide band frequency modulation (WBFM). Pro správnou funkcionalitu je nutné zadat parametry modulace, přičemž nejdůležitější z nich je maximální frekvenční odchylka Δf od nosné frekvence f_c , které mají přímou souvislost s šířkou pásma vyjádřenou rovnicí 10. Ta je zpravidla několikanásobně větší než u AM modulací.

Na druhou stranu dovoluje přenos audio ve stereo módu a poměrně vysoké kvalitě, která se blíží kompaktnímu disku. Nejběžněji používané nastavení parametrů FM modulace využívané ve většině zemí Evropy je $\Delta f = 75\text{kHz}$ a $f_{max} = 15\text{kHz}$ nebo $f_{max} = 53\text{kHz}$ v případě stereo vysílání. Toto nastavení určuje maximální šířku pásma 200kHz .

$$BW_{FM} = 2(\Delta f + f_{max}) \quad (10)$$

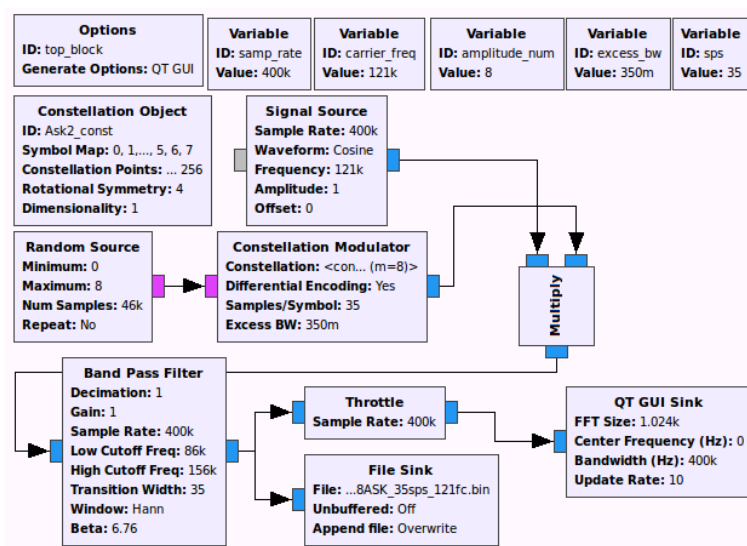


Obrázek 9: Schéma PM modulátoru

Posledním simulovaným typem analogového provozu byla fázová modulace. Ta je principiálně velice podobná modulaci frekvenční. Pro přenos informace využívá změnu okamžité fáze a chování úhlově modulovaného signálu, což se v komplexní rovině téměř neliší od výše popsaného FM. Realizace v GRC je rovněž velmi podobná jako u schématu 8, neboť jak je vidět na obrázku 9, jediným rozdílem je použití GRC modulu Phase mod s lehce odlišnými parametry. Šířka pásma potřebná pro přenos fázově modulovaného signálu zůstává totožná s minimální šířkou pro FM přenos, která je reprezentována rovnicí 10.

6.1.3 Schémata digitálních modulátorů

Kromě analogových modulací, které nacházejí uplatnění zejména v oblasti klasického rádiového vysílání, existuje také množství digitálních modulací. Využívají se zejména pro přenos diskretních signálů, jako je například televizní vysílání či provoz bezdrátových sítí (Wi-Fi, mobilní sítě). Je tedy logické, že modulační (datový) signál má vždy diskretní podobu. Nejčastěji se jedná o proud bitů. Nosný signál je stejně jako u analogového provozu spojitý a vždy dosahuje konečného počtu změn amplitudy, frekvence nebo fáze, což je hlavní rozdíl oproti analogovým formám modulace. Při realizaci digitálních modulátorů v rozhraní GRC byl jako zdroj modulačního signálu použit náhodný generátor binárních čísel. Po samotném procesu modulace signál prošel pásmovou propustí, čímž byla zajištěna minimální potřebná šířka pásma.

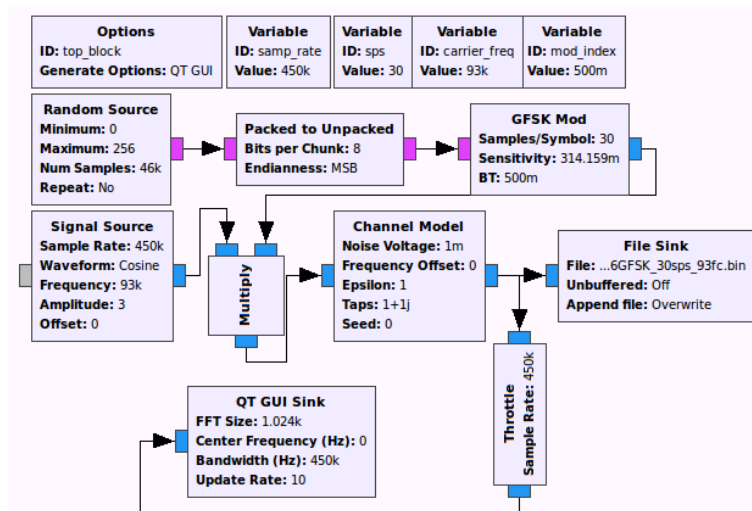


Obrázek 10: Schéma ASK modulátoru

Klíčování amplitudovým posuvem, realizované dle schématu 10, je v podstatě speciální případ klasické AM modulace. Rozdíl je pouze v typu modulačního signálu, který má v případě ASK číslicovou podobu. Proces modulace je pak řešen pomocí konstelačního modulátoru, v němž se mapují jednotlivé hodnoty modulačního signálu na různé úrovně amplitudy. Výsledný modulovaný signál vyžaduje minimální šířku pásma rovnu modulační rychlosti. Výpočet lze vyjádřit také rovnicí 11, kde d nabývá hodnoty 0 nebo 1 a S označuje modulační rychlost v baudech. [11]

$$BW_{ASK} = (1 + d)S \quad (11)$$

Realizace modulátoru pro klíčování frekvenčním posuvem byla poměrně jednoduchá. Opět byl použit již existující modul FSK Mod z GRC. Jedná se o téměř čistou formu FSK modulace, která však navíc využívá Gaussův filtr. Ten zajistí plynulejší přechody mezi jednotlivými frekvencemi a omezí tak šířku pásma, kterou můžeme spočítat pomocí rovnice 12 závislou na modulační rychlosti S a maximální frekvenční odchylce Δf



Obrázek 11: Schéma FSK modulátoru

od frekvence nosné vlny. [11]

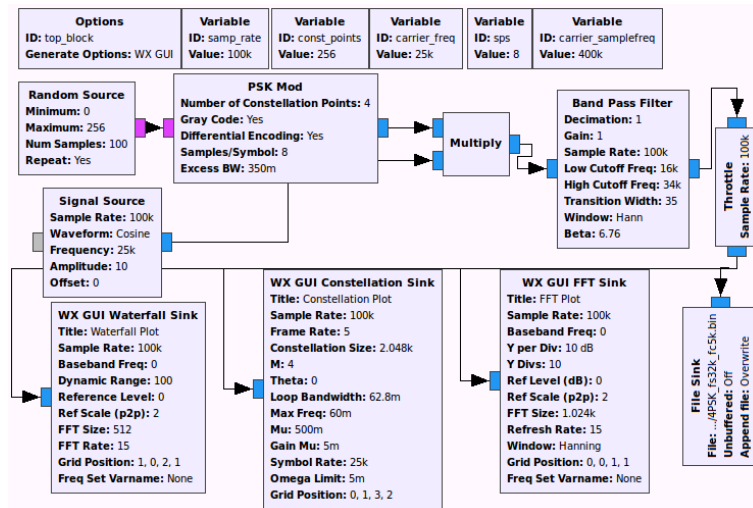
$$BW_{FSK} = S + 2\Delta f \quad (12)$$

PSK neboli klíčování fázovým posuvem je v současnosti společně s QAM velmi oblíbeným způsobem přenosu digitálních dat. Spolehá na využití konečného počtu změn okamžité fáze reprezentující data v modulačním signálu. GRC prostředí má pro tento druh modulace samostatný modul jménem PSK Mod. Ten umožňuje nastavit veškeré potřebné parametry včetně diferenciationálního kódování, které je užitečným pomocníkem při následné demodulaci signálu v přijímači. Minimální šířka pásma pro PSK modulaci závisí především na přenosové rychlosti B neboli bit ratu a je definována vztahem 13. [11]

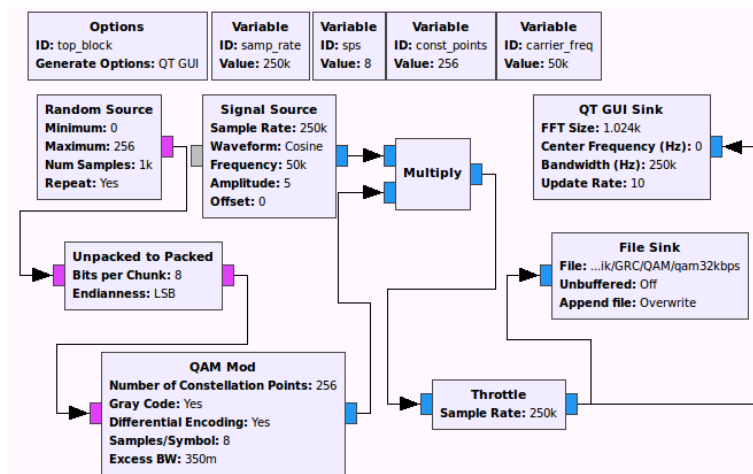
$$BW_{PSK} = 2B \quad (13)$$

Konečně nejpoužívanější modulací je bezesporu kvadraturní amplitudová modulace neboli QAM, která nezávisle kombinuje metody ASK a PSK. Tím je možno dosáhnout mnohem většího počtu konstelačních bodů než v případě PSK. Proto je z pohledu rychlosti přenosu dat velice efektivní. Se zvyšujícím se řádem modulace M lze jednak přenést vždy $\log_2(M)$ bitů v jednom stavu a navíc dochází k zúžení šířky pásma, jež je dána vztahem 14, která je přímo úměrná modulační rychlosti S .

$$BW_{QAM} = S \quad (14)$$



Obrázek 12: Schéma PSK modulátoru



Obrázek 13: Schéma QAM modulátoru

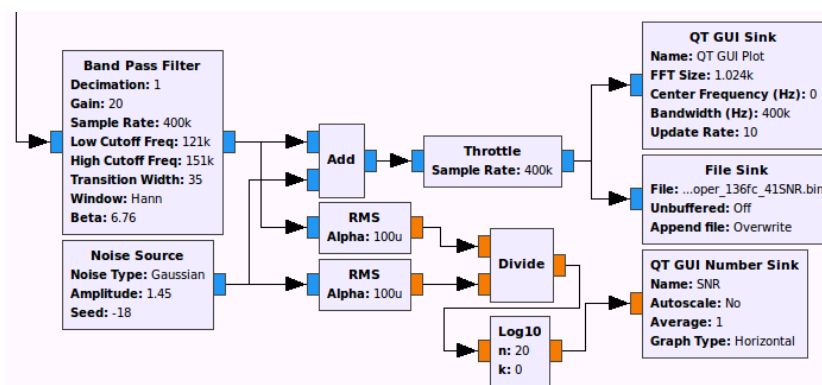
6.1.4 Vstupní data s podílem šumu

Aby byla trénovací množina, tvořená vektory klíčových charakteristik, pro učení neuronové sítě dostatečně reprezentativní, bylo nezbytné do ní zahrnout také výpočty ovlivněné šumem. Toho bylo dosaženo vygenerováním signálů s kontrolovaným poměrem SNR v rozmezí 10-50 dB. Ty byly následně použity jako vstupní data pro RTAD a výsledné vektory vloženy do tréninkového datasetu. Mezní hodnota 10 dB byla určena na základě pozorování hodnot získaných v 6.3, kdy nižší odstup signálu od šumu již nepřevyšoval určenou prahovou hodnotu.

Výpočet SNR je definován rovnicí 8. Pro alternativní vyjádření lze použít vzorec 15, využívající měření kvadratického průměru amplitud signálu a šumu v čase.

$$SNR = 20 \log_{10} \left(\frac{RMS(A_s)}{RMS(A_n)} \right) [dB] \quad (15)$$

Realizace výše zmíněného výpočtu v prostřední GRC je patrná z obrázku 14. Nejprve



Obrázek 14: Schéma měření SNR z kvadratického průměru amplitud signálu a šumu

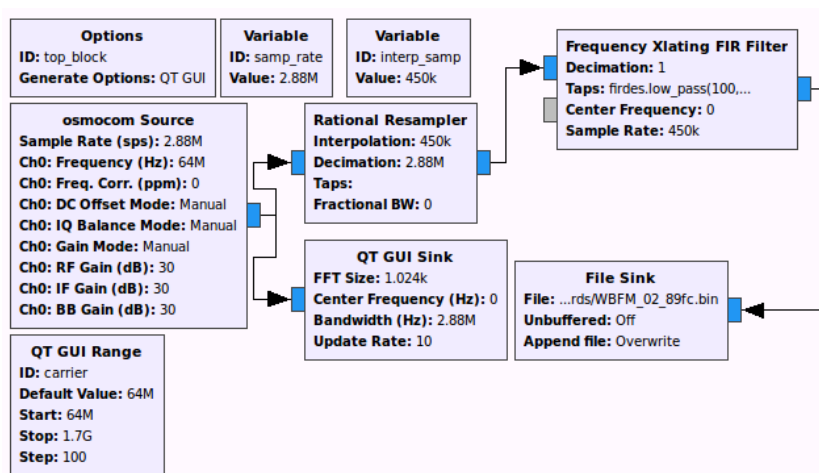
vstupuje do pásmové propusti modulovaný signál z libovolného modulátoru uvedeného v podkapitolách 6.1.2 a 6.1.3. Poté je modulovaný signál sečten s AWGN, přičemž dochází ke kontinuálnímu měření kvadratického průměru amplitud šumu i modulovaného signálu. Podíl kvadratických průměrů je logaritmován a vynásoben konstantou 20. Výsledné SNR prezentuje v decibelech při běhu simulace graf společně s číselnou hodnotou. Poměr signál šum je možné měnit nastavením maximální amplitudy šumu nebo zisku pásmové propusti, popřípadě zvyšováním či snižováním amplitudy nosné vlny v samotném modulátoru.

6.1.5 Záznam reálného rádiového provozu

Prostředí umožňující příjem skutečného rádiového vysílání začíná vždy u hardwaru. Pro účely této diplomové práce bylo vybráno zařízení SDB 522RT od firmy Sencor, které je založeno na čipu Realtek RTL2832U. Frekvenční rozsah přístroje 48,25 MHz - 863,25 MHz je

dán zejména použitým tunerem Elonics E4000. Šířka pásma se pohybuje mezi hodnotami 0,9 - 2,88 MHz s dynamickým rozsahem zhruba 48 dB.

Z výše uvedených parametrů je zřejmé, že SDB 522RT byl primárně navržen pro příjem frekvenčně modulovaného rádiového vysílání. V horní polovině frekvenčního spektra je teoreticky schopen zpracovat i televizní signál šířený pomocí pozemního digitálního vysílání (DVB-T). Frekvenční rozsah použitého SDR přijímače byl navíc rozšířen použitím upconverteru Ham It Up ve verzi 1.2. Ten umožnil zachycení rádiového provozu vysílaného na dlouhých, středních a krátkých vlnách. Všechny signály přijímané v rozmezí od zhruba 0,1 MHz do 30 MHz jsou před vstupem do tuneru E4000 vynásobeny 125 MHz oscilátorem. Software, umožňující zaznamenání dat vysílaných na dané frekvenci, byl realizován pomocí blokového schématu 15 v rozhraní GRC. Komunikace



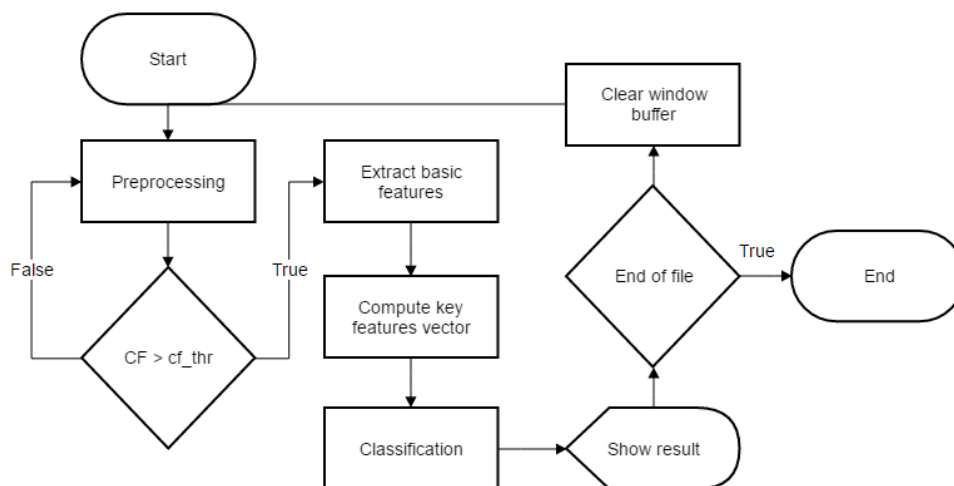
Obrázek 15: Schéma pro příjem rádiových signálů pomocí čipu RTL2832U

mezi počítačem a čipem RTL2832U je zprostředkovávána blokem *osmocom Source*, který není v rámci GNU Radia standardně dostupný a je ho zapotřebí doinstalovat. Nastavení parametrů vstupního modulu odpovídá omezením použitého SDR přijímače. Následuje proces převzorkování signálu na nižší vzorkovací kmitočet, sníží se tak výpočetní náročnost a signál je možné dále zpracovat v RTAD. Posledním krokem před samotným uložením přijímaných dat do binární podoby je jejich filtrování pomocí dolní propusti. Modul *Frequency Xlating FIR Filter* zajišťuje kromě zlepšení poměru signál šum také oříznutí zájmové části přijímaného spektra. Výsledný radiový signál je ukládán v základním pásmu.

6.2 Vývojový diagram

Propojení jednotlivých procesů prováděných v rámci RTAD nejlépe vystihuje příloha 24, jejíž zjednodušená podoba se nachází na obrázku 16. Operace na sebe logicky navazují a jsou částečně konfigurovatelné uživatelem pomocí uživatelského rozhraní. Po spuštění

aplikace, zadání všech parametrů, včetně cesty ke zdrojovému souboru, je spuštěna samotná klasifikace.



Obrázek 16: Vývojový diagram programu RTAD

Nejprve se provádí deserializace modelu neuronové sítě a načítání komplexních vzorků ze vstupního souboru. Počet zpracovávaných hodnot je specifikován uživatelem pomocí parametru velikost okna. Pokud je v době čtení povoleno použití pásmové propusti, jednotlivé vzorky analyzovaného signálu jsou postupně filtrovány a vkládány do bufferu o velikosti okna zvoleného uživatelem. V opačném případě je z binárního souboru přečteno najednou požadované množství vzorků. Jakmile jsou vstupní hodnoty k dispozici, provede nad nimi algoritmus pro výpočet DFT. V rámci kalkulace Fourierovy transformace software zároveň interpretuje její výsledky, aby následně mohl ve frekvenční oblasti určit činitele výkyvu, jež byl využit v podkapitole 6.3 k detekci signálu. Pokud je získaná hodnota pro aktuální časový úsek zkoumaného signálu dostatečně vysoká, pokračuje algoritmus extrakcí okamžité amplitudy, fáze a frekvence. Ještě před statistickou analýzou průběhu signálu je potřeba normalizovat a centrovat vektor okamžité amplitudy, který následně projde algoritmem DFT. Dále jsou vyjádřeny hodnoty nelineární složky fáze. Při výpočtu je nutné fázi rozbalit, protože jsou ignorovány periodické násobky. Tento problém je popsán v podkapitole 3.3. [10]

Teprve až jsou připraveny všechny potřebné charakteristiky vstupního signálu, může software začít s jejich statistickou analýzou. Pro zvýšení efektivity jsou výpočty klíčových statistických vlastností, představených podkapitolou 6.5, paralelizovány. Jakmile je dokončeno poslední vlákno obstarávající statistické kalkulace, je všech šest proměnných zapsáno do pole. Z hlediska neuronové sítě jsou tato data považována za vstupní. Na jejich základě se model sítě pokusí provést klasifikaci a přiřadit tak právě zkoumaný časový segment vstupních vzorků k jednomu typu modulace.

6.3 Detekce signálu a šumu

Aby mohl software efektivně pracovat se vstupními daty jak v offline, tak online módu, bylo nutné implementovat algoritmus pro detekci signálu v zarušeném prostředí. Výsledkem je ignorování vstupních dat, které reprezentují pouze šum nebo nemají dostatečný odstup od šumu. Jinými slovy Radio traffic automatic detector (RTAD) nezahájí proces klasifikace typu modulace pro dané okno, pokud se v něm nenachází špička s dostatečným výkonem.

Detektor funguje na principu crest factoru neboli činitele výkyvu. Ten je definován jako poměr maximální hodnoty amplitudy k jejímu kvadratickému průměru. Výpočet probíhá ve frekvenčním spektru, proto je po načtení vstupních dat nutné nejprve provést jejich Fourierovu transformaci. V závislosti na uživateli může před jejím výpočtem proběhnout filtrování jednotlivých vzorků v časové rovině.[17]

Definice 6.1 Činitel amplitudy CF je definován jako:

$$CF = \frac{|A|_{max}}{RMS(A)} \quad (16)$$

kde A je vektor amplitudy a RMS , reprezentující kvadratický její průměr, je vyjádřen jako [17]:

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^N A[i]^2} \quad (17)$$

Výsledek je následně porovnán s prahovou úrovní činitele amplitudy šumu, která je malá a na základě pozorování obvykle nepřesahuje hodnotu pět. Jakákoliv vyšší hodnota naznačuje výskyt užitečného signálu ve vstupním proudu dat.


6.4 Aplikace filtrů

Digitální filtry jsou při digitálním zpracování signálů obecně důležitým nástrojem. Představují efektivní způsob jak zajistit kvalitní vstup pro další dílčí výpočty jednotlivých klíčových charakteristik signálu, jejichž informační hodnota se při klesajícím SNR rapidně zhoršuje. Z tohoto hlediska byla implementace komplexní pásmové propusti jednou ze stěžejních bodů celého vývoje.

Při hledání informací týkajících se pásmových propustí a filtrů s konečnou impulsní odezvou (FIR) obecně bylo zjištěno, že jejich použití se dělí na dvě fáze. V první řadě je potřeba kýžený filtr navrhnout na základě parametrů zadaných uživatelem. Následně je filtr pomocí konvoluce aplikován na vstupní signál.[12]

6.4.1 Návrh pásmové propusti

Při vytváření tohoto algoritmu jsem se inspiroval třídou `firdes`, která je součástí jádra GNU Radia. Nabízí poměrně dobře čitelnou implementaci návrhu komplexní pásmové



Obrázek 17: Blokové schéma konvoluční FIR filtru

propusti, přičemž využívá okénkové metody. Je však napsána v jazyce C++, proto bylo potřeba její část přepsat.

Návrhová funkce pracuje s parametry dolní mezní frekvence, horní mezní frekvence, vzorkovací frekvence, šířka přechodového pásma, zisk a útlum. Nejprve je spočítán řád filtru nejvíce ovlivnitelný šířkou přechodového pásma. Čím užší přechodové pásmo, tím je filtr v mezních frekvencích ostřejší, ale rovněž narůstá i jeho řád, a tím výpočetní složitost. [12]

Druhým krokem je využití návrhu ideální dolní propusti pomocí Hannova okna. Hodnotu koeficientů dolní propusti lze částečně ovlivnit parametry zisku a útlumu. Musíme však pamatovat na maximální hodnotu útlumu pro Hannovo okno, která je rovna 44 dB. Jakmile získáme koeficienty dolní propusti, je již snadné získat na základě vypočtené frekvence a fáze jednotlivé komplexní koeficienty pásmové propusti. Výstupem algoritmu je tedy vektor komplexních koeficientů filtru, které jsou později použity v konvoluční fázi filtrování. [12]

6.4.2 Implementace konvoluce FIR filtru

Základním předpokladem při konstrukci konvoluční části FIR filtru jsou komplexní koeficienty, získané správným návrhem filtru dle podkapitoly 6.4.1, a vstupní vzorky čteného signálu v časové doméně. Jednotlivé vzorky jsou zpracovávány jeden po druhém. Blokové schéma 17 dobře znázorňuje získání filtrovaného vzorku pomocí konvoluce.

Pokud se podíváme na funkcionalitu reprezentovanou schématem 17, dojdeme k závěru, že se v podstatě jedná o operaci založenou na využití klouzavého průměru. Na vstupu konvolučního algoritmu je vždy aktuálně načtený vzorek reprezentovaný jako $x[n]$, kde n je index daného vzorku v právě zpracovávaném okně. Řád filtru je určen počtem koeficientů a označuje se M . Třída implementující konvoluci má k dispozici buffer pro $M - 1$ předchozích vzorků, který je ve schématu znázorněn pomocí zpožďovacích členů Z^{-1} . Při vstupu nového vzorku do filtru se všechny ostatní hodnoty uložené v paměti filtru posunou o jednu pozici doprava a poslední z nich se zahodí. Na místo prv-

ního indexu se pak zapíše hodnota vstupního vzorku. Následuje operace násobení, realizovaná cyklem, všech hodnot z bufferu s příslušnými koeficienty filtru a jejich součet. Operace násobení a sčítání vycházejí z pravidel pro počítání s komplexními čísly. Výstupem konvoluce je filtrovaný vzorek $y[n]$. Matematický popis filtru je definován rovnicí 18. [12]

$$y[n] = \sum_k h_k \cdot x[n - k] \quad (18)$$

6.5 Implementace klíčových faktorů

K získání informací o druhu modulace použité v signálu byla využita statistika. Konkrétně se jedná o analýzu základních popisných charakteristik signálu jako je okamžitá amplituda, frekvence či fáze a povahy jejich změn v čase. Azzouz a Nandi [7] vytvořili pro tyto účely devět statistických rysů, které vypovídají o chování vlny v daném časovém úseku. Jsou to:

- Maximální hodnota spektrální výkonové hustoty normalizované centrované okamžité amplitudy (γ_{max})
- Směrodatná odchylka absolutní hodnoty nelineární složky okamžité fáze (σ_{ap})
- Směrodatná odchylka přímé hodnoty nelineární složky okamžité fáze (σ_{dp})
- Symetrie frekvenčního spektra kolem nosné frekvence (P)
- Směrodatná odchylka absolutní hodnoty normalizované centrované okamžité amplitudy (σ_{aa})
- Směrodatná odchylka absolutní hodnoty normalizované centrované okamžité frekvence (σ_{af})
- Směrodatná odchylka normalizované centrované okamžité amplitudy (σ_a)
- Špičatost normalizované centrované okamžité amplitudy (μ_{42}^a)
- Špičatost normalizované centrované okamžité frekvence (μ_{42}^f)

Význam výše zmíněných klíčových statistických rysů je přirozeně závislý na konkrétní popisné proměnné, s níž pracují. Například γ_{max} nabývá vyšších hodnot pro signály přenášející informace v amplitudě. Naopak pro druhy provozu, které využívají k přenosu dat frekvenci či fázi, jsou pozorované hodnoty o několik řádů nižší, téměř nulové. Podobné informace udává i hodnota σ_{aa} , která je navíc schopna rozlišit dvoustavovou a více stavovou modulaci typu ASK. Veličina σ_{ap} je naopak založena na změnách fáze. Teoreticky se více mění v případě, že je informace uložena formou změny argumentů komplexních vzorků. Hodnota σ_{dp} slouží k odlišení modulace B-PSK od ostatních druhů provozu, které nevyužívají změn fáze. V případě charakteristiky P se dá v podstatě mluvit o šikmosti grafu výkonu ve frekvenčním spektru. Dle hodnoty lze určit, zda

je většina energie distribuována na pravé či levé straně od nosné frekvence nebo je její rozložení symetrické. Tato vlastnost je využitelná při detekování silně symetrických modulací jako je AM, ASK a jejich nesymetrických opaků, tedy například FM či SSB. Hlavním účelem proměnné σ_{af} je rozlišit mezi B-FSK a 4-FSK provozem. Lze ji však využít i k doplnění informace o tom, zda se jedná o modulaci založenou na změnách frekvence. Konečně μ_{42}^a a μ_{42}^f zkoumají kompaktnost rozložení amplitudy a frekvence. Je podle nich teoreticky možné rozlišit mezi AM a ASK, respektive FSK provozem.[5, 8, 13]

Implementace jednotlivých klíčových statistických charakteristik se opírá o jejich matematické definice. Téměř polovina z nich je přitom založena na využití běžně používaného vzorce pro směrodatnou odchylku. Na základě prostudování jednotlivých klíčových jevů z nich bylo vybráno šest, podle kterých je teoreticky možné rozpoznat vybrané modulace (AM, FM, PM, ASK, FSK, PSK, QAM). Konkrétně jde o rysy γ_{max} , σ_{ap} , σ_{dp} , σ_{aa} , σ_{af} a symetrie frekvenčního spektra P.

Definice 6.2 Maximální hodnota spektrální výkonové hustoty normalizované centrované okamžité amplitudy je definována jako:

$$\begin{aligned}\gamma_{max} &= \frac{\max |DFT(A_{cn})|^2}{N} \\ A_{cn}[n] &= \frac{A[n]}{\mu_A} - 1\end{aligned}\quad (19)$$

kde A je vektor okamžité amplitudy a μ_A aritmetický průměr okamžité amplitudy. [5, 6, 8]

Definice 6.3 Směrodatná odchylka absolutní hodnoty nelineární složky okamžité fáze je definována jako:

$$\sigma_{ap} = \sqrt{\frac{1}{N_c} \left(\sum_{A_n[n] > A_t} \phi_{NL}^2[n] \right) - \left(\frac{1}{N_c} \sum_{A_n[n] > A_t} |\phi_{NL}[n]| \right)^2} \quad (20)$$

kde N_c je počet komplexních vzorků, které jsou nad úrovní šumu a $\phi_{NL}[n]$ je vektor nelineární složky okamžité fáze. [5, 6, 8]

Definice 6.4 Směrodatná odchylka přímé hodnoty nelineární složky okamžité fáze je definována jako:

$$\sigma_{dp} = \sqrt{\frac{1}{N_c} \left(\sum_{A_n[n] > A_t} \phi_{NL}^2[n] \right) - \left(\frac{1}{N_c} \sum_{A_n[n] > A_t} \phi_{NL}[n] \right)^2} \quad (21)$$

kde N_c je počet komplexních vzorků, které jsou nad úrovní šumu a $\phi_{NL}[n]$ je vektor nelineární složky okamžité fáze. [5, 6, 8]

Definice 6.5 Symetrie frekvenčního spektra kolem nosné frekvence je definována jako:

$$\begin{aligned} P &= \frac{P_L - P_U}{P_L + P_U} \\ P_L &= \sum_{n=1} f_{cn} |X_c[n]|^2 \\ P_U &= \sum_{n=1} f_{cn} |X_c[n + f_{cn} + 1]|^2 \\ f_{cn} &= \frac{f_{cn} N}{f_s} - 1 \end{aligned} \quad (22)$$

kde f_s je vzorkovací frekvence, f_c je frekvence nosné vlny a $(f_{cn} + 1)$ odpovídá pozici vzorku korespondujícímu s nosnou frekvencí. [5, 6, 8]

Definice 6.6 Směrodatná odchylka absolutní hodnoty normalizované centrované okamžité amplitudy je definována jako:

$$\sigma_{aa} = \sqrt{\frac{1}{N} \left(\sum_{n=1}^N A_{cn}^2[n] \right) - \left(\frac{1}{N} \sum_{n=1}^N |A_{cn}[n]| \right)^2} \quad (23)$$

kde N je počet komplexních vzorků a $A_{cn}[n]$ je vektor normované centrované okamžité amplitudy. [5, 6, 8]

Definice 6.7 Směrodatná odchylka absolutní hodnoty normalizované centrované okamžité frekvence je definována jako:

$$\begin{aligned} \sigma_{af} &= \sqrt{\frac{1}{N_c} \left(\sum_{A_n[n] > A_t} f_N^2[n] \right) - \left(\frac{1}{N_c} \sum_{A_n[n] > A_t} |f_N[n]| \right)^2} \\ f_N[n] &= \frac{f_m[n]}{f_s} \\ f_m[n] &= f[n] - \mu_f \end{aligned} \quad (24)$$

kde N_c je počet komplexních vzorků, které jsou nad úrovní šumu, $f[m]$ je vektor okamžité frekvence a μ_f je aritmetický průměr okamžité frekvence. [5, 6, 8]

Definice 6.8 Směrodatná odchylka normalizované centrované okamžité amplitudy je definována jako:

$$\sigma_a = \sqrt{\frac{1}{N_c} \left(\sum_{A_n[n] > A_t} A_{cn}^2[n] \right) - \left(\frac{1}{N_c} \sum_{A_n[n] > A_t} A_{cn}[n] \right)^2} \quad (25)$$

kde N_c je počet komplexních vzorků, které jsou nad úrovní šumu a $A_{cn}[n]$ je vektor okamžité normalizované centrované amplitudy. [5, 8]

Definice 6.9 Špičatost normalizované centrované okamžité amplitudy je definována jako:

$$\mu_{42}^a = \frac{E\{A_{cn}^4[n]\}}{\{E\{A_{cn}^2[n]\}\}^2} \quad (26)$$

kde $A_{cn}[n]$ je vektor okamžité normalizované centrované amplitudy. [5, 8]

Definice 6.10 Špičatost normalizované centrované okamžité frekvence je definována jako:

$$\mu_{42}^f = \frac{E\{f_N^4[n]\}}{\{E\{f_N^2[n]\}\}^2} \quad (27)$$

kde $f_N[n]$ je vektor okamžité normalizované frekvence. [5, 8]

6.6 Vytváření modelů neuronové sítě

Proces klasifikace modulací v programu RTAD se plně spoléhá na model neuronové sítě vytvořený pomocí knihovny Encog. Jak je uvedeno v podkapitole 6.2, množinou vstupů pro neuronovou síť jsou vektory složené z klíčových statistických charakteristik, jež jsou extrahovány před realizací samotné klasifikace. Model tak pracuje v šesti-rozměrném prostoru, obsahujícím dimenze odpovídající jednotlivým klíčovým vlastnostem amplitudy, frekvence i fáze, viz. kapitolu 6.5.

Při výběru vhodných typů neuronové sítě byli zvoleni dva kandidáti. Prvním z nich byl nejpoužívanější model typu Feed forward, který je založen na vzájemném propojení všech neuronů sousedících vrstev. Nespornou výhodou řešení tohoto typu je robustnost vůči chybnému rozhodnutí některého z neuronů, neboť výsledek je silně závislý i na zbytku sítě. Druhou možností bylo použití o něco sofistikovanějšího modelu RBF s teoreticky lepšími vlastnostmi pro učení i schopností si lépe poradit se vstupními daty ovlivněnými šumem. Hlavním rozdílem mezi klasickou vícevrstvou Feed forward sítí a RBF spočívá v metodice rozhodování. Zatímco perceptrony, využívané v modelech Feed forward, se v aktivačních funkcích spoléhají na sumu vah vstupních hodnot, v případě RBF je tomu jinak. Namísto prostého sčítání vah RBF počítá rozdíly mezi vstupními hodnotami a jejich vahami. Vznikne tak vektor vzdáleností, který je následně poslán do váhové funkce, nejčastěji založené na Gaussově křivce. Součástí procesu je vynásobení vektoru hodnotou proměnné, představující trend dané aktivační funkce. RBF navíc používá dva typy neuronů, perceptrony a radiální neurony. [9]

Nejprve byly pomocí aplikace RTAD.TrainingTool vytvořeny zvažované typy modelů neuronové sítě. V případě obou modelů byl zvolen proces učení s učitelem a metodou Back-propagation. Trénink probíhal výhradně na uměle vytvořených datech s plnou kontrolou nad poměrem signálu a šumu. Cílem bylo naučit neuronovou síť co nejlépe rozlišovat mezi sedmi druhy modulací (AM, FM, PM a ASK, FSK, PSK, QAM). Každá modulační představa představuje jednu třídu ve výstupní vrstvě modelu. Pro dosažení co nejlépe rozlišovacího souboru tréninkových dat byl každý zkoumaný druh rádiového provozu reprezentován zhruba deseti tisíci vstupními vektory. Základem pro výpočet tréninkových vektorů bylo 11,5 GB binárních dat vygenerovaných pomocí simulací, jimž je věnována podkapitola

6.1.1, v prostředí GRC. Jedním z nejdůležitějších parametrů při kalkulaci vektorů, které posloužily modelu jako učební vstup, byla velikost okna udávající počet komplexních vzorků, z nichž vzešly jednotlivé statistické rysy signálů. Čím je zkoumaný časový úsek delší, tím výmluvnější informace lze statistickou analýzou získat. Standardní velikost pro tréninkové účely byla nastavena na $16\,384$ komplexních vzorků. Počet vzorků nutných pro vytvoření trénovací množiny vektorů jediného druhu modulace se tedy pohyboval okolo $1,6384 \cdot 10^8$ a celkové množství zpracovaných vzorků bylo rovno $1,198473216 \cdot 10^9$. Před tím než byla vstupní data použita při učení modelu, musela projít normalizací, kterou zajistila třída `NormalizationHelper`.

Knihovna `Encog` nabízí možnost křížové validace vytvářeného modelu. Data byla pro tento účel rozdělena v poměru 70% tréninkových ku 30% validačním hodnot a počet opakování byl nastaven na hodnotu pět. Statický seed pro náhodné rozdělení dat zajistil, že při každém validačním cyklu byla použita stejná kontrolní množina vektorů. Dle výsledku křížové validace, který je roven průměru validační chyby jednotlivých iterací, lze teoreticky usuzovat, jak spolehlivý bude model v praxi. Síť typu RBF měla při učení validační chybu zhruba 9,79% a vedla si tak o něco lépe než základní Feed forward s chybou okolo 21,75%. Nicméně až testování na konkrétních datech prokázalo, který z modelů je skutečně lepší.

Jakmile bylo dokončeno učení i validace, vytvořený model byl společně s přidruženou instancí třídy `NormalizationHelper` serializován v binární podobě na disk.

6.7 Výstup

Výstupem je vždy konkrétní typ modulace predikovaný modelem neuronové sítě. Klasifikace je přirozeně do značné míry závislá na tom, jak dobře dokáže používaný model rozlišit mezi jednotlivými typy modulací. Avšak jistou roli může hrát i volba parametrů na vstupu společně s poměrem SNR.

Samotný výstup je reprezentován třemi způsoby. Aplikace disponuje textovou konzolí, která zobrazuje uživateli detailnější informace o prováděných operacích a případných chybách. Jedná se spíše o výpis detailnějších informací o aktuálním stavu zpracovávaných dat. Uživatel má díky tomu možnost sledovat historii průběhu klasifikace.

Druhým prvkem je seznam podporovaných druhů modulací, zobrazující procentuální rozdělení klasifikačních rozhodnutí, které model provedl. Software si ukládá uživatelem specifikovaný počet posledních několika rozhodnutí. Na základě vytvářeného bufferu dojde vždy při zpracování nového okna k přepočítání procentuálního rozdělení podporovaných tříd a aktualizaci uživatelského rozhraní. Platí pravidlo, čím větší množství rozhodnutí si program pamatuje, tím je výstup přesnější, ale viditelnost změny modulace naopak pomalejší. Příliš velké číslo může negativně ovlivnit výpočetní výkon, proto je nezbytné vždy zvolit rozumný kompromis.

Poslední formou výstupu je jednoduchý graf zobrazující výsledek DFT. Obnovovací frekvence grafu je v základu nastavena na 100 milisekund a nejsou tedy vykreslována všechna zpracovávaná okna. Uživatel má možnost změnit rychlost obnovování grafu i přiblížení libovolného bodu ve frekvenčním spektru.

7 Validace úspěšnosti řešení

Testování úspěšnosti klasifikace jednotlivých druhů rádiového provozu pomocí aplikace RTAD probíhalo v první fázi na uměle vytvořených datech, získaných pomocí modulatorů popsaných v podkapitolách 6.1.2 a 6.1.3. Modulační signál, který byl použit pro vytváření testovacích množin, nebyl totožný s žádným z modulačních signálů použitých při vytváření trénovacích vektorů pro neuronovou síť. Rovněž byly obměňovány parametry a nosná frekvence v závislosti na typu modulace.

Klíčovou roli sehrál při testech parametr SNR. Poměr signál šum byl postupně snižován od úplné absence šumu ve zkoumaném signálu až na úroveň 15 dB. Rušení bylo vždy přidáváno do již dříve vygenerovaného, původně bezšumového signálu. Pro zjednodušení a zpřehlednění testů byly vytvořeny tři skupiny testovacích dat, rozdělené dle odstupu signálu od šumu po deseti decibelech, mezi hodnotami 15 dB až 45 dB. Data byla doplněna také o čtvrtou skupinu, která nebyla rušením nijak ovlivněna.

V druhé fázi byly do binární podoby navzorkovány signály získané odposlechem běžně dostupného rádiového provozu. Určitou kontrolu nad poměrem SNR u reálně přijímaného signálu poskytlo zapojení GRC modulu Frequency Xlating FIR Filter s využitím koeficientů dolní propusti.

7.1 Ověření vhodnosti použitých statistických charakteristik

Jedním ze stěžejních předpokladů, umožňujících klasifikaci modulačních technik na základě statistické analýzy vstupního signálu, je výběr vhodných charakteristik, které jsou nositeli informace o změnách vlny v čase. Podmínkou je jejich dostatečná vzájemná diverzita. Vzájemný odstup statistických příznaků v závislosti na druhu použité modulace lze znázornit vnesením jejich hodnot z vybraného časového úseku do grafu.

Průběh klíčové charakteristiky γ_{max} naznačený grafem na obrázku 18, jejíž hodnota je přímo úměrná změnám okamžité amplitudy, ukazuje poměrně znatelný rozdíl mezi dvěma třídami modulací. Techniky rádiového provozu, využívající k uchování informace o průběhu modulačního signálu amplitudu (AM, ASK), nabývají v tomto parametru vyšších hodnot. V pomyslném středu se pohybuje kvadrurní amplitudová modulace, skládající se v podstatě z kombinace ASK a PSK. Nakonec se hodnoty pro skupinu modulací založených na změnách frekvence blíží nule.

Druhou zkoumanou klíčovou charakteristikou je σ_{aa} , jež by se dle podkapitoly 6.5 měla informacemi podobat výše zmíněné γ_{max} . Trend na obrázku 19 dokazuje, že hodnoty, kterých σ_{aa} nabývá, jsou o něco vyšší. Celková schopnost oddělení amplitudových a frekvenčních modulací je však v podstatě totožná. Z grafu je patrný lepší odstup mezi jednotlivými křivkami. Vzhledem k tomu, že klasifikační model nezahrnuje rozpoznávání konkrétního počtu stavů digitálních modulací, lze jeden z dvojice parametrů γ_{max} , σ_{aa} teoreticky považovat za redundantní.

Oba průběhy amplitudově závislých, klíčových charakteristik naznačují, že může na jejich základě docházet v rámci neuronové sítě k mylné záměně tříd AM a ASK, popřípadě ASK, PSK a QAM. Hodnoty rysů nesoucí informaci o průběhu amplitudy odpovídají teoretickým předpokladům ze sekce 6.5.



Vlastnosti signálu, jejichž hodnota je založena na zkoumání změn fáze, by dle teoretického základu měly jasně vyhranit prostor mezi skupinou modulací FM, FSK, PSK, QAM a trojicí AM, ASK, BPSK. Křivky na obrázku 20 ukazují částečnou shodu s očekávaným výsledkem. Zapadají zde do sebe pouze příbuzné modulace, frekvenční a fázová, z části zasahující do digitálního klíčování frekvenčním posuvem. Dále je patrná skupina tvořená amplitudovou modulací a její digitální obdobou ASK. Lze navíc očekávat, že pomocí rysu σ_{ap} bude možné lépe oddělit provoz na bázi QAM, který se však bohužel stále značně překrývá s binárním klíčováním fázovým posuvem.


Jak je vidět z grafu 21, proměnná σ_{dp} , zkoumající směrodatnou odchylku přímé hodnoty fáze, nabývá v porovnání s obrázkem 20 ve většině bodů téměř dvojnásobných hodnot. Hlavním účelem je schopnost oddělit binární PSK provoz od ostatních druhů modulací, které nejsou založeny na změnách fáze. Jedná se o veličinu používanou k doplnění informace nesené v σ_{ap} .

Obě klíčové charakteristiky σ_{ap} , σ_{dp} jsou dle průběhu jejich hodnot vhodné k oddělení digitálních modulací se změnou fáze od příbuzných frekvenčních technik provozu včetně analogové fázové modulace. Prudká změna křivky reprezentující modulaci PSK je zapříčiněna zvýšením počtu stavů fáze ve vstupním signálu. To odpovídá skutečnosti, že zhruba ve stém okně bylo ukončeno zpracování B-PSK signálu a na vstup byla přivedena data reprezentující vícestavový PSK provoz.


Hodnota proměnné σ_{af} reflektuje změny ve frekvenci a je primárně určena pro oddělení binárního a vícestavového klíčování frekvenčním posuvem. Z průběhu se dá usuzovat, že částečně také napomůže k vzájemnému rozlišení provozů PSK a QAM. Naopak pro skupinu analogové frekvenční a fázové modulace není tento zkoumaný parametr prakticky využitelný.

Konečně šestou statistickou charakteristikou, která byla analyzována pomocí grafu hodnot 23, je symetrie frekvenčního spektra okolo nosného kmitočtu. Dle průběhu je vidět, že například odchylka hodnot pro ASK, AM či QAM není příliš vzdálená od nuly. Naopak v případě asymetrických FM a PM modulací je zřetelné, jak se energie ve frekvenčním spektru přesouvá v závislosti na povaze přenášené informace.


Obrázek 18: Průběh klíčové veličiny γ_{\max} Obrázek 19: Průběh klíčové veličiny σ_{aa}




Obrázek 20: Průběh klíčové charakteristiky σ_{ap}



Obrázek 21: Průběh klíčové charakteristiky σ_{dp}



Obrázek 22: Průběh klíčové charakteristiky σ_{af}



Obrázek 23: Průběh symetrie frekvenčního spektra

7.2 Testy nad umělými daty

Teoretický vývoj testů modelů Feed forward a Radial basis function nad uměle simulovanými daty byl dán zejména velikostí chyby křížové validace při jejich učení. Dle předpokladů vyplývajících z kapitoly 6.6 byly lepší výsledky očekávány od RBF, neboť měla při trénovacím procesu úspěšnosti až 90%. Základní topologie sítě typu Feed forward si vedla asi o deset procent hůře. Druhým faktorem, který byl použit k ověření robustnosti testovaných modelů vůči vlivu rušení na vstupní signál, byla míra aditivního bílého šumu. Větší odstup signálu od šumu měl teoreticky snižovat procento chybných klasifikací.

Výsledky testů jsou rozděleny do grafů dle příslušného modelu neuronové sítě a poměru signál šum ve vstupních datech. Z jednotlivých sloupců je vždy jasné patrné poměrné rozdělení vstupních vektorů mezi dané typy modulací. Tabulky relativních četností testů úspěšnosti klasifikace pro model Feed forward i Radial basis function jsou uvedeny níže.

Modulace	AM	FM	PM	ASK	FSK	PSK	QAM	Celkem
AM	10,34%	0,00%	0,00%	89,66%	0,00%	0,00%	0,00%	100,00%
FM	0,31%	48,45%	22,62%	19,22%	0,00%	5,27%	4,13%	100,00%
PM	0,93%	51,44%	40,41%	4,12%	0,00%	1,86%	1,24%	100,00%
ASK	1,10%	0,00%	0,00%	98,90%	0,00%	0,00%	0,00%	100,00%
FSK	20,76%	7,98%	16,27%	44,71%	0,00%	4,39%	5,89%	100,00%
PSK	0,66%	17,61%	16,76%	61,86%	0,00%	0,00%	3,11%	100,00%
QAM	17,09%	32,04%	0,00%	43,79%	0,00%	0,19%	6,89%	100,00%

Tabulka 3: Výsledky modelu RBF na nezarušeném vstupním signálu

Již při letném pohledu na tabulku 3 je dobře viditelná převaha třídy reprezentující klíčování amplitudovým posuvem. Při bližším zkoumání zjistíme, že výraznější tendenci spadat do třídy ASK mají druhy provozů jí příbuzné. Jedná se zejména o amplitudovou modulaci, ale nemalé procento představují také modulace PSK či QAM.

V případě frekvenčně založených provozů si RBF vede o poznání hůř. Frekvenční a fázová modulace jsou poměrně v pořádku, nicméně v případě FSK nastává problém. Sít' není schopna tento druh provozu na základě vstupních klíčových charakteristik vůbec rozeznat. Navíc zhruba 45% dat posoudila jako amplitudově klíčovaný provoz, který je založen na úplně jiném principu. Pouze necelých 28% vstupů je klasifikováno jako příbuzné modulace FM, PM a PSK. O podobných chybách se dá mluvit i v případě QAM a PSK.

Naopak konkurenční model neuronové sítě Feed forward si při testu nad totožnými daty vedl mnohem lépe. Poměrně snadno a přesně dokázal rozlišit mezi kmitočtovými a amplitudovými modulacemi, jak vyplývá z tabulky 4. Žádná ze zkoumaných modulací nepřevládá v rozdělení jiné, nepříbuzné modulace. Model má oproti výsledkům v tabulce 3 mnohem lepší schopnost rozlišit klíčování frekvenčním či fázovým posuvem, i když i zde je jasná tendence inklinovat k příbuzným analogovým druhům provozu. Rov-

Modulace	AM	FM	PM	ASK	FSK	PSK	QAM	Celkem
AM	85,32%	0,00%	0,00%	0,41%	0,00%	14,27%	0,00%	100,00%
FM	0,00%	86,57%	12,09%	0,00%	1,03%	0,00%	0,31%	100,00%
PM	0,10%	33,55%	51,93%	0,00%	0,00%	13,81%	0,62%	100,00%
ASK	4,61%	0,00%	0,00%	67,41%	0,00%	0,00%	27,98%	100,00%
FSK	0,20%	32,54%	19,26%	0,00%	31,83%	7,09%	9,08%	100,00%
PSK	0,66%	0,00%	0,00%	16,01%	0,00%	50,28%	33,05%	100,00%
QAM	0,68%	0,00%	6,12%	0,29%	16,41%	33,88%	42,62%	100,00%

Tabulka 4: Výsledky modelu Feed forward na nezarušeném vstupním signálu

něž lze očekávat větší množství chyb při identifikaci PSK a QAM, což není překvapivé, neboť se jedná podobné techniky.

Následující testy modelů neuronových sítí Feed forward i RBF proběhly se vstupními vzorky v poměru SNR v rozmezí od 35 dB do 45 dB. Síla signálu je při takto vysokém odstupu signálu od šumu považována za velmi dobrou, proto byla očekávána i vysoká úspěšnost při klasifikaci modulací.

Modulace	AM	FM	PM	ASK	FSK	PSK	QAM	Celkem
AM	28,62%	1,45%	0,00%	69,32%	0,00%	0,31%	0,30%	100,00%
FM	1,11%	26,54%	71,11%	0,37%	0,00%	0,49%	0,38%	100,00%
PM	12,62%	57,04%	15,54%	8,45%	0,00%	4,59%	1,76%	100,00%
ASK	1,03%	0,00%	0,00%	98,97%	0,00%	0,00%	0,00%	100,00%
FSK	0,00%	53,32%	22,52%	2,84%	0,00%	12,43%	8,89%	100,00%
PSK	0,57%	34,31%	0,00%	65,03%	0,00%	0,09%	0,00%	100,00%
QAM	0,58%	0,00%	0,00%	91,45%	0,00%	0,39%	7,58%	100,00%

Tabulka 5: Výsledky modelu RBF pro odstup signálu od šumu 35 - 45 dB

Tabulka 5 ukazuje, že chování sítě RBF se přidáním minimálního množství šumu v porovnání se situací v tabulce 3 příliš nezlepšilo. Za zmínku sice stojí vyšší procento správně vytríděných vstupů amplitudové modulace, stejně jako částečné zlepšení v případě FM a FSK díky poklesu podílů amplitudových druhů provozu. Avšak k nesrovnatelně většímu nárůstu chyby ve prospěch modulačních tříd AM a ASK došlo u fázově modulovaných signálů. Model nebyl vůbec schopen rozpoznat nejen FSK, ale i klíčování fázovým posuvem, které naopak zapadlo kdesi mezi ASK a frekvenční modulaci. K malému zlepšení došlo dle hodnot vyplývajících z tabulky 6 v případě sítě Feed forward. Přidáním šumu dokázala síť efektivněji generalizovat vstupní hodnoty. Menší chyby v některých případech splynuly s převládajícím podílem příbuzných modulací. Konkrétně se jedná všechny testované kategorie s výjimkou FM a PM. Nejmarkantnější změnu tohoto typu lze sledovat v kategorii FSK, kde dokázala neuronová síť generalizovat méně výrazné chybové podíly PM, PSK i QAM směrem k FSK více příbuznému FM. V případě frekvenční a fázové modulace došlo ještě k jednomu zajímavému jevu. Jejich vzájemná chyba je v poměru téměř 1:1.

Modulace	AM	FM	PM	ASK	FSK	PSK	QAM	Celkem
AM	86,45%	1,76%	3,93%	0,00%	0,10%	0,00%	7,76%	100,00%
FM	0,62%	30,74%	60,12%	0,00%	0,12%	3,21%	5,19%	100,00%
PM	0,63%	37,96%	42,75%	0,00%	11,46%	0,00%	7,20%	100,00%
ASK	31,97%	0,00%	0,00%	0,00%	0,00%	0,00%	68,03%	100,00%
FSK	0,00%	74,72%	0,00%	0,00%	25,19%	0,09%	0,00%	100,00%
PSK	0,66%	0,09%	0,00%	0,00%	0,00%	34,59%	64,66%	100,00%
QAM	0,78%	0,10%	0,00%	0,00%	0,00%	22,15%	76,97%	100,00%

Tabulka 6: Výsledky modelu Feed forward pro odstup signálu od šumu 35 - 45 dB

V pořadí třetí test opět snížil odstup signálu od šumu o 10 dB. Jeho cílem bylo dále zkoumat dopad vlivu zarušení vstupního signálu na proces a úspěšnost klasifikace obou modelů neuronové sítě.

Modulace	AM	FM	PM	ASK	FSK	PSK	QAM	Celkem
AM	15,51%	7,65%	0,00%	74,87%	0,00%	1,24%	0,73%	100,00%
FM	0,62%	16,17%	82,47%	0,62%	0,00%	0,12%	0,00%	100,00%
PM	13,45%	52,97%	12,93%	13,87%	0,00%	4,69%	2,09%	100,00%
ASK	0,76%	0,00%	0,00%	99,24%	0,00%	0,00%	0,00%	100,00%
FSK	0,00%	18,46%	59,79%	1,55%	0,00%	15,54%	4,66%	100,00%
PSK	0,57%	34,97%	0,00%	49,01%	0,00%	9,52%	5,93%	100,00%
QAM	0,58%	0,19%	0,00%	68,99%	0,00%	13,51%	16,73%	100,00%

Tabulka 7: Výsledky modelu RBF pro odstup signálu od šumu 25 - 35 dB

Snižující se hodnota parametru SNR naznačila čím dál tím zřetelnější nevhodnost modelu sítě typu RBF pro řešení problému klasifikace modulací. Již při předchozím testu, kdy byla kvalita užitečného signálu velice dobrá, začaly být výsledky modelu smíšené a nejednoznačné, jak je vidět v tabulce 5. Tento sestupný trend se potvrdil i v následujícím testu, viz tabulka 7, při použití vstupů, které byly šumem více ovlivněny.

Modulace	AM	FM	PM	ASK	FSK	PSK	QAM	Celkem
AM	97,31%	0,00%	1,03%	0,00%	0,10%	0,00%	1,61%	100,00%
FM	0,62%	49,38%	41,72%	0,00%	0,25%	6,42%	1,61%	100,00%
PM	0,63%	44,63%	37,33%	0,00%	11,37%	0,10%	5,94%	100,00%
ASK	34,41%	0,00%	0,00%	0,00%	0,00%	0,00%	65,59%	100,00%
FSK	0,17%	74,55%	0,00%	0,00%	25,11%	0,17%	0,00%	100,00%
PSK	0,57%	0,19%	0,00%	0,00%	0,00%	52,69%	46,55%	100,00%
QAM	0,88%	0,00%	0,00%	0,00%	0,00%	33,14%	65,98%	100,00%

Tabulka 8: Výsledky modelu Feed forward pro odstup signálu od šumu 25 - 35 dB

Menší náchylnost k chybám v závislosti na SNR projevil spíše druhý klasifikační model. Při vyhodnocení výsledků testů s daty v rozmezí poměru užitečného signálu k šumu

25-35 dB, nedošlo dle tabulky 8 k zásadnímu zhoršení modelu co se týká konzistentnosti chování. Při rozhodování na základě vektorů, odpovídajícím vzorkům modulovaných pomocí AM, udělal model zhruba o 10% více chyb než v předcházejícím testu, jak je patrné z tabulky 6. Nicméně alespoň polovina z této chyby spadá do kategorie QAM modulace, která využívá jak změny fáze, tak i amplitudy. U frekvenční modulace se zvýšil poměr chyby standardně ve prospěch fázové modulace. Při snižující se kvalitě signálu můžeme očekávat, že model typu Feed forward bude klasifikovat vyšší procento PSK vstupů spíše jako QAM modulaci. Zbytek tříd zůstal téměř nezměněn.

Poslední skupina validačních dat spadala do šumové kategorie SNR = 15 - 25 dB. Vzhledem ke znatelnému zarušení signálu byla velice pravděpodobná degradace rozpoznávacích schopností obou testovaných modelů.

Modulace	AM	FM	PM	ASK	FSK	PSK	QAM	Celkem
AM	10,66%	9,63%	2,28%	75,16%	0,00%	1,04%	1,23%	100,00%
FM	0,49%	11,98%	86,79%	0,74%	0,00%	0,00%	0,00%	100,00%
PM	13,89%	50,68%	14,63%	15,47%	0,00%	2,92%	2,41%	100,00%
ASK	0,40%	0,00%	0,00%	99,60%	0,00%	0,00%	0,00%	100,00%
FSK	0,00%	10,61%	72,99%	0,43%	0,00%	13,46%	2,51%	100,00%
PSK	0,19%	51,75%	0,00%	33,08%	0,00%	8,29%	6,69%	100,00%
QAM	0,19%	31,10%	0,00%	63,17%	0,00%	1,46%	4,08%	100,00%

Tabulka 9: Výsledky modelu RBF pro odstup signálu od šumu 15 - 25 dB

Model RBF dosáhl dle tabulky 9 při testu s SNR 15-25dB téměř totožných výsledků jako u vstupních vektorů se zarušením zpracovávaného signálu odpovídajícímu 25 - 35 dB. Dá se tedy usuzovat, že již při SNR = 25 - 35 dB je schopnost odlišit od sebe jednotlivé třídy hraniční.

Modulace	AM	FM	PM	ASK	FSK	PSK	QAM	Celkem
AM	74,95%	4,76%	6,42%	0,10%	0,93%	0,00%	12,84%	100,00%
FM	0,25%	25,80%	66,42%	0,00%	0,00%	0,74%	6,79%	100,00%
PM	0,52%	35,84%	50,05%	0,00%	11,70%	0,00%	1,89%	100,00%
ASK	1,62%	0,00%	0,00%	35,73%	0,00%	0,00%	62,65%	100,00%
FSK	0,09%	31,58%	43,05%	0,00%	25,20%	0,00%	0,08%	100,00%
PSK	0,47%	0,28%	10,18%	0,00%	0,00%	34,50%	54,57%	100,00%
QAM	0,58%	0,19%	0,00%	0,00%	0,00%	16,04%	83,19%	100,00%

Tabulka 10: Výsledky modelu Feed forward pro odstup signálu od šumu 15 - 25 dB

Jak je vidět na výsledcích uvedených v tabulce 10 v případě modelu Feed forward došlo k větší odezvě na snížení SNR než v případě RBF. Neuronová síť byla schopna lépe rozoznat zejména klíčování amplitudovým posuvem. Při testování na klasifikaci PSK však došlo k nárůstu chyby klasifikace ve prospěch příbuzné analogové fázové modulace.

První fáze validace modelů neuronových sítí dopadla dle očekávání. Na základě výsledků bylo rozhodnuto o použití základní neuronové sítě typu Feed forward, neboť

bylo její chování přesnější a robustnější než u konkurenčního RBF. Rovněž byly zjištěny předpoklady chování modelů vzhledem k velikosti SNR. Dále proběhla identifikace problematických tříd modulací a na základě sledování bylo zjištěno, jaké skupiny rádiových provozů mohou být na základě použitých klíčových charakteristik špatně odlišitelné.

7.3 Testy nad reálnými daty

Do druhé části testování byl na základě výsledků získaných v podkapitole 7.2 vybrán model neuronové sítě typu Feed forward. Validace byla prováděna nad daty představujícími reálný rádiový provoz. K zachycení vstupů z různých částí frekvenčního spektra posloužilo zařízení SDB522RT. Vzhledem k technickým omezením hardwaru bylo možné zachytit pouze provoz vysílaný v kmitočtovém pásmu od 48,25 MHz do 863,25 MHz. Zdrojem dat využívajících FM modulaci byly standardní rozhlasové stanice využívající spektrum zhruba 85-110 MHz. Dále bylo zaznamenáno vysílání na frekvencích od 300 MHz do 320 MHz. Byly zde nalezeny stanice využívající ASK a PSK modulaci. Modulace QAM či QPSK byla extrahována z pásma využívaného bezpečnostními a záchrannými složkami na kmitočtech okolo 391 MHz.

Kmitočtové pásmo využívané k vysílání amplitudově modulovaným provozem je bohužel pod hranicí citlivosti použitého tuneru. V rámci hledání radiových stanic se rovněž nepodařilo naladit provoz využívající digitální modulaci FSK. Výsledky klasifikačních testů jsou uvedeny v tabulce 11.

Modulace	AM	FM	PM	ASK	FSK	PSK	QAM	Celkem
AM	1,00%	0,00%	0,00%	88,00%	0,00%	0,00%	11,00%	100,00%
FM	0,07%	0,00%	0,00%	0,75%	99,11%	0,07%	0,00%	100,00%
ASK	70,44%	0,00%	0,00%	29,59%	0,00%	0,00%	0,00%	100,00%
PSK	0,00%	0,00%	0,00%	0,00%	31,07%	68,93%	0,00%	100,00%
QAM	0,00%	0,00%	0,00%	46,23%	0,00%	53,77%	0,00%	100,00%

Tabulka 11: Úspěšnost klasifikačního modelu sítě Feed forward pro reálná data

Prvním testovaným druhem provozu byl rádiový provoz vysílaný na středních a dlouhých vlnách pomocí modulace AM. Správně bylo klasifikováno pouze jedno procento ze všech vstupních hodnot. Většina pak připadla do kategorie reprezentující klíčování amplitudovým posuvem ASK, které je v podstatě speciální formou AM omezenou konečným počtem amplitud.

Je patrné, že se přesnost modelu při reálných vstupních datech snížila. V případě frekvenčně modulovaných signálů má neuronová síť tendenci inklinovat spíše k příbuzné třídě FSK. Rozdíl mezi oběma druhy provozu je přitom stejný jako v případě AM a ASK, tedy FSK využívá konečný počet změn frekvence.

Klíčování amplitudovým posuvem má naopak tendenci směřovat spíše k analogové amplitudové modulaci. Nicméně model dokázal správně rozpoznat, která veličina je analyzovaným provozem využívána pro přenos informací. Příčina větší chyby se může nacházet na straně poměrně malého odstupu vstupního signálu od šumu, na který jsou právě amplitudové modulace značně citlivé.

Při testech s modulací PSK bylo zhruba 69% vstupů klasifikováno správně. Zbýlých asi 31% přiřadila neuronová síť do třídy modulací FSK. S množinou vektorů reprezentující klíčování fázovým posuvem souvisí rovněž kvadraturní amplitudová modulace, která při testech dopadla o něco hůře. Model ji rozdělil na dvě podmnožiny, ASK v 46%

a PSK v 54% případů. Vzhledem k tomu, že se QAM skládá právě z kombinace modulací ASK a PSK, je výsledek stále částečně reprezentativní.

Při detailním průzkumu vypočtených charakteristik bylo zjištěno, že pokud jsou na vstup RTAD přivedena data z reálného prostředí, jsou vypočtené hodnoty určitých klíčových charakteristik vyšší než je tomu v případě simulací. Toto platí zejména pro frekvenční modulaci, u níž příznak γ_{max} vzrostl o několik řádů, ale stále je o řád až dva nižší, než hodnoty vypočtené pro opačnou třídu amplitudových modulací. Podobný fenomén lze pozorovat i v případě σ_{aa} , kdy jak u frekvenčních, tak amplitudových modulací nastává posun o řád až dva směrem vzhůru. Jak můžeme pozorovat, tento fakt je možnou příčinou záměny typů modulací, jejichž klíčové charakteristiky byly v trénovací množině relativně blízko u sebe. Druhým problémem může být číselná reprezentace klíčových charakteristik, vztahující se na příliš mnoho desetinných míst. Například klíčová charakteristika γ_{max} nabývá pro FM provoz v rámci trénovací množiny dat extrémně nízkých hodnot s řádem okolo 10^{-6} až 10^{-9} . Modelu by mohlo při klasifikaci pomoci, kdyby se při výpočtech použilo omezené množství desetinných míst, například čtyři.

8 Závěr

V rámci diplomové práce na téma Automatická identifikace druhu provozu pro SDR rádio byl proveden rozbor konceptu SDR přijímačů a vysílačů, včetně popisu jejich fungování, výhod i nevýhod. Byl položen teoretický základ pro práci s komplexní reprezentací diskretních vzorků, zahrnující výpočty základních vlastností popisujících průběh signálu v čase, jimiž jsou okamžitá amplituda, frekvence a fáze. Nedílnou součástí implementace tvoří klíčové charakteristiky získané pomocí statistické analýzy výše zmíněných základních popisných charakteristik.

V praktické části práce, zahrnující vývoj řešení pro klasifikaci modulací, byl nejprve implementován vstup reprezentovaný čtením komplexních vzorků z binárního souboru. Následovala realizace vzorců pro výpočet popisných charakteristik signálu a ověření jejich funkcionality. Výsledky testů ukázaly, že získané výstupní hodnoty odpovídají teoretickým předpokladům.

Realizace vzorců, definovaných v podkapitole 6.5, používaných v rámci statistické analýzy vstupních dat byla o něco složitější. Asi největší problém, jehož řešení se zakládá na inspiraci čerpané z algoritmu používaného knihovnou Matlab, se stalo rozbalení fáze [10]. Důvodem byla nejen špatná dokumentace řešení, ale také jeho značná časová složitost. Validace korektnosti implementace klíčových charakteristik vyžadovala větší množství vstupních signálů, které byly vygenerovány pomocí softwaru GRC. Výsledky odpovídaly teoretickým předpokladům. Vyšlo však najevo neefektivní využití výpočetního výkonu počítače, a proto došlo k zefektivnění vykonávaných úloh pomocí jejich paralelizace. Použité optimalizační řešení vedlo ke zkrácení výpočetního času. Z grafického znázornění průběhů hodnot uvedeného v podkapitole 7.1 jednotlivých klíčových charakteristik vyplynulo, že některé z nich nesou informace, které jsou vzhledem ke skupinám podporovaných modulací redundantní a mohly by být z výpočtů vynechány.

V průběhu vytváření modelů neuronových sítí byly vybrány dvě konkurenční topologie Radial basis function a Feed forward. Volba byla ovlivněna zejména faktem, že se jedná o dva typy sítí, které jsou nejvíce využívány při řešení klasifikačních problémů. Proces učení popsáný v sekci 6.6 měl za cíl vytvořit co možná nejvhodnější model každé ze zkoumaných topologií, schopný co nejefektivněji řešit problematiku klasifikace druhů modulace na základě výše popsané statistické analýzy vstupních vzorků. Ačkoliv první křížová validace naznačovala lepší výsledky v případě modelu postaveného na topologii RBF, následné testy nad neznámými umělými daty jeho kvalitu nepotvrdily. Důvodem byla nedostatečná schopnost rozpoznat modulaci FSK a dominantní postavení třídy reprezentující ASK, do níž spadalo až příliš velké procento vstupů. O poznání lépe dopadl ve stejných testech konkurenční model typu Feed forward. Jeho chování se jevílo jako konzistentnější a reakce v podobě zvyšující se chyby vlivem klesajícího odstupu užitečného signálu od šumu byla přijatelná. I zde však docházelo k nepřesnostem zejména při rozpoznávání vstupů modulovaných provozem FSK.

Na základě testů s umělými daty byl vybrán vhodnější z modelů, tedy Feed forward. Ten byl následně podroben validaci s použitím vstupních dat ve formě reálného rádiového vysílání. Značný vliv na funkci RTAD mělo správné naladění nosné frekvence, zvolená šířka pásma a odstup signálu od šumu. Vzhledem k tomu, že použitý hardware

byl vybaven tunerem s frekvenčním rozsahem 48,25-863,25 MHz obohaceným o upconverter pro příjem krátkých, středních a dlouhých vln, podařilo se zachytit pouze pět, konkrétně AM, FM, ASK, PSK a QAM, z šesti podporovaných druhů provozu. Částečné omezení představovala také anténa dodávaná výrobcem, která je nevyhovující zejména pro příjem DVB-T vysílání.

Testy s reálnými daty odhalily, že hodnoty získané výpočtem jejich klíčových charakteristik jsou v porovnání s hodnotami, které byly naměřeny při použití simulovaných signálů, řádově vyšší. Důvodem mohou být příliš optimisticky nastavené parametry modulátorů při vytváření simulací vstupních dat. Rozdíly hodnot se projeví u všech zkoumaných druhů provozu, a tudíž by jejich separace neměla být teoreticky ovlivněna. Pokud však vezmeme v úvahu skutečnost, že použitý model neuronové sítě byl trénován na řádově rozdílných hodnotách, pak mohl rozdíl hodnot mít zcela nepochybně negativní vliv na úspěšnost klasifikace. Chování modelu při testech s reálnými vstupními daty nebylo úplně konzistentní. Frekvenčně modulované signály měly tendenci více konvergovat k FSK. Příbuzný digitální a analogový amplitudový provoz ASK, AM si model navzájem také dost pletl. Klíčování fázovým posuvem bylo rozpoznáno poměrně úspěšně a v případě QAM provozu měl model tendenci rozdělovat klasifikaci vektorů mezi třídy ASK respektive PSK, které QAM používá. Neuronová síť dokázala na základě vstupních informací správně určit jakým způsobem je vstupní signál modulován. V průběhu klasifikace nedocházelo k větší degradaci výsledků ve prospěch nepříbuzných tříd zkoumaných modulací.

Nezávisle na vzniku této práce došlo o několik let dříve k podobnému výzkumu na Vysokém učení technickém v Brně [13]. Hlavním rozdílem byla především zvolená klasifikační metoda a podporované druhy modulací. Výzkum byl zaměřen na rozlišování digitálních modulací pomocí prahového klasifikátoru. Na druhou stranu dokázal představený algoritmus navíc rozlišit počet stavů, kterých jednotlivé digitální modulační nabývají. Úspěšnost konkurenčního řešení, založeného na prahování je lepší než v případě zde popsáných modelů neuronové sítě Feed Forward a RBF. Rovněž je méně náchylný k nízkému poměru SNR.

Ke zlepšení úspěšnosti klasifikace s využitím neuronové sítě by teoreticky přispělo přiblížení hodnot v trénovací množině blíže k hodnotám naměřeným s reálnými signály na vstupu. Pozitivní účinek by v tomto směru mohlo přinést rovněž omezení počtu desetinných míst u klíčových charakteristik.

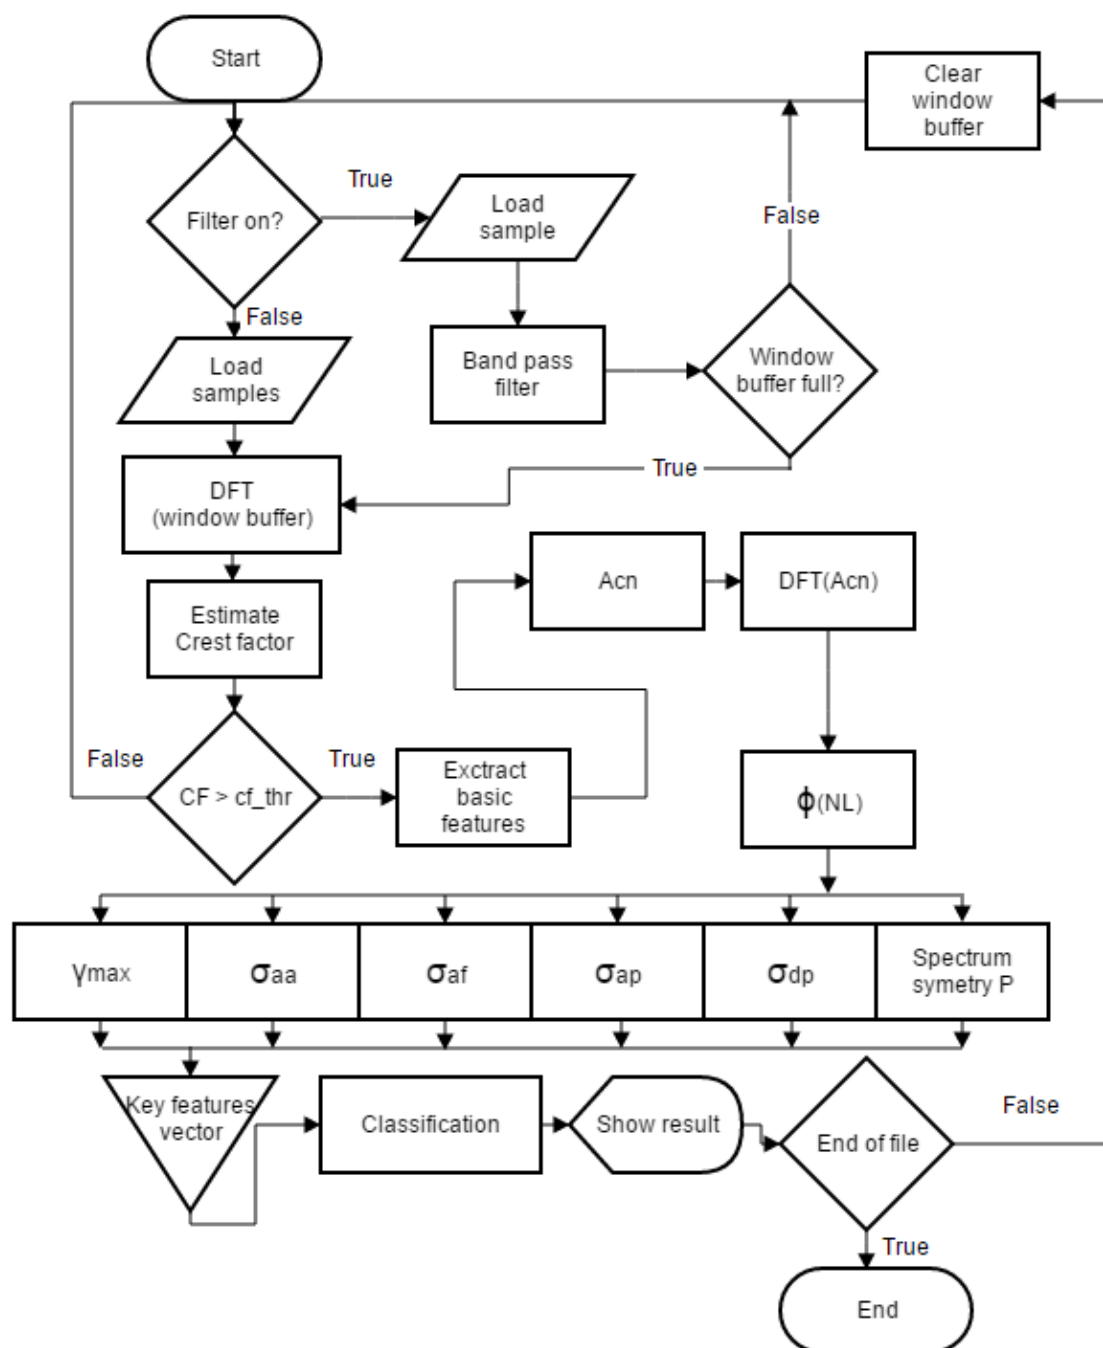
9 Reference

- [1] VASEGHI, Saeed V. *Advanced Digital Signal Processing and Noise Reduction*. 2. vyd. John Wiley & Sons Ltd. 2010. ISBN 0-470-84162-1. Kapitola 2, Noise and distortion, s. 29-43.
- [2] ZHU, Zhechen. *Automatic classification of digital communication signal modulations*. Londýn, 2014. 156s. Disertační práce na Katedře elektroniky a počítačového inženýrství Brunelské univerzity v Londýně.
- [3] REED, Jeffrey H. *Software Radio - A modern Approach to Radio Engineering*. Upper Saddle River: Prentice Hall, 2002. ISBN 0130811580
- [4] AHN, W.H. Automatic Modulation Classification of Digital Modulation Signals Based on Gaussian Mixture Model. In *UBICOMM 2014 : The Eighth International Conference on Mobile Ubiquitous Computing, Systems, Services and Technologies*, IARIA - Mezinárodní akademie, výzkum, a průmyslová asociace. Řím: IARIA XPS Press, 2014. s. 275-280
- [5] ZHU, Zhechen. *Automatic Modulation Classification: Principles, Algorithms and Applications*. Zhechen Zhu a A.K. Nandi. 1. vyd. Pondicherry: John Wiley & Sons, 2015. 184 s. ISBN 978-1-118-90649-1.
- [6] BAGGA, J. a TRIPATHI, N. Automatic Modulation Classification Using Statistical Features In Fading Environment. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*. August 2013, vol. 2, no. 8, s. 3701-3708.
- [7] AZZOUZ, Elsayed a NANDI, Asoke. *Automatic Modulation Recognition of Communication Signals*. 1. vyd. Springer Science & Business Media, 1996. 218 s. ISBN 978-1-4419-5166-3.
- [8] POPOOLA, Jide J. a OLST, R. Automatic Recognition of Analog Modulated Signals Using Artificial Neural Networks. *Computer Technology and Application*. January 2011, vol. 2, s. 29-35.
- [9] SANTOS, R.; RUPP, M; BONZI, S.; FILETI A.M. Comparison Between Multilayer Feedforward Neural Networks and a Radial Basis Function Network to Detect and Locate Leaks in Pipelines Transporting Gas. *Chemical engineering transactions*. 2013, vol. 32, s 1375-1380.
- [10] KARAM, Zahi Nadim. *Computation of the One-Dimensional Unwrapped Phase*. Boston: Massachusetts Institute of Technology. Department of Electrical Engineering and Computer Science, 2006, 102 s., 62 s. příloh. Vedoucí diplomové práce Alan V. Oppenheim.

-
- [11] VACHHANI, K. Design Analysis of Digital Modulation Schemes with GNU Radio. In *Second INTERNATIONAL CONFERENCE ON NETWORKS, INFORMATION & COMMUNICATIONS*. Bangalore: Reasearch Gate, May 2015, 4 s.
 - [12] KOLAWOLE, E.S., ALI, W.H., COFIE, P., FULLER, J., TOLLIVER, C. and OBIONMON, P. Design and Implementation of Low-Pass, High-Pass and Band-Pass Finite Impulse Response (FIR) Filters Using FPGA. *Circuits and Systems*. 2015, vol. 6, s 30-48. <http://dx.doi.org/10.4236/cs.2015.62004>
 - [13] KUBÁNKOVÁ, A.; KUBÁNEK, D. Digital Modulation Recognition Based on Feature, Spectrum and Phase Analysis and its Testing with Disturbed Signals. In *Proceedings of the 10th WSEAS International Conference on Signal Processing (SIP '11)*. Lanzarote, Spain: WSEAS Press, 2011. s. 162-166. ISBN: 978-1-61804-005- 3.
 - [14] BOUALEM, Boashash. Estimating and Interpreting the Instantaneous Frequency of a Signal-Part 2: Algorithms and Applications. In *Proceedings of the IEEE*, duben 1992, vol. 80, No. 4. ISSN: 0018-9219/92.
 - [15] SCHROEDER, Manfred Robert. *Fractals, Chaos, Power Laws: Minutes from an Infinite Paradise*. 1 vyd. Dover Publications, Incorporated, 2012. 429. s. ISBN 978-0-486-13478-9.
 - [16] GRAYVER, Eugene. *Implementing Software Defined Radio*. Ilustrované vyd. Springer Science & Business Media, 2012. 270s. ISBN 978-1-441-99332-8.
 - [17] *Power Meter Tutorials*. URL<http://www.yokogawa.com/ymi/tutorial/tm-tutorial_wt_08.htm>[cit. 2016-04-02].
 - [18] GALLAGER, Robert G. *Principles of Digital Communication*, Cambridge University Press, 2008. ISBN 0521879078
 - [19] MÍŠEK, Pavel. *Softwarově Definované Rádio v provozních souvislostech*. Praha: Český radioklub, 2012 [cit. 2015-29-11]. [online] Dostupné z <http://www.crk.cz/>. Poslední úpravy 13. 10 .2015
 - [20] BARNNES, Arthur E. The calculation of instantaneous frequency and instantaneous bandwidth. *Geophysics*. November 1992, vol. 57, no. 11, s 1520-1524.
 - [21] PRAVEEN, S. Thakur. Trends in Automatic Modulation Classification for Advanced Data Communication Networks. In *International Journal of Advanced Research in Computer Engineering & Technology*, únor 2015, vol. 4, vydání 2, s. 496-507. ISSN: 2278 – 1323.

A Appendix

A.1 Vývojový diagram řešení



Obrázek 24: Vývojový diagram RTAD